



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21c/2018/07.10.17.20-TDI

## **ESTIMATIVA DE BIOMASSA FLORESTAL NO ESTADO DO MATO GROSSO A PARTIR DE DADOS DO LIDAR E LANDSAT**

Erone Ghizoni dos Santos

Dissertação de Mestrado do  
Curso de Pós-Graduação  
em Sensoriamento Remoto,  
orientada pelo Dr. Yosio Edemir  
Shimabukuro, aprovada em 25 de  
julho de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3REBD95>>

INPE  
São José dos Campos  
2018

## **PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

## **COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):**

### **Presidente:**

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

### **Membros:**

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

### **BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

### **REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)

### **EDITORAÇÃO ELETRÔNICA:**

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SESID)

Murilo Luiz Silva Gino - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21c/2018/07.10.17.20-TDI

## **ESTIMATIVA DE BIOMASSA FLORESTAL NO ESTADO DO MATO GROSSO A PARTIR DE DADOS DO LIDAR E LANDSAT**

Erone Ghizoni dos Santos

Dissertação de Mestrado do  
Curso de Pós-Graduação  
em Sensoriamento Remoto,  
orientada pelo Dr. Yosio Edemir  
Shimabukuro, aprovada em 25 de  
julho de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3REBD95>>

INPE  
São José dos Campos  
2018

Dados Internacionais de Catalogação na Publicação (CIP)

---

Santos, Erone Ghizoni dos.

Sa59e      Estimativa de biomassa florestal no estado do Mato Grosso a partir de dados do LiDAR e LANDSAT / Erone Ghizoni dos Santos. – São José dos Campos : INPE, 2018.

xx + 105 p. ; (sid.inpe.br/mtc-m21c/2018/07.10.17.20-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

Orientador : Dr. Yosio Edemir Shimabukuro.

1. Amazônia. 2. Biomassa. 3. Floresta degradada. 4. LiDAR.  
5. Sensoriamento Remoto. I.Título.

CDU 630\*2:528.8

---



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Erone Ghizoni dos Santos**

Título: "ESTIMATIVA DE BIOMASSA FLORESTAL NO ESTADO DO MATO GROSSO A PARTIR DE DADOS DO LIDAR E LANDSAT"

Aprovado (a) pela Banca Examinadora  
em cumprimento ao requisito exigido para  
obtenção do Título de **Mestre** em  
**Sensoriamento Remoto**

Dra. Maria Isabel Sobral Escada

  
\_\_\_\_\_  
Presidente / INPE / SJCampos - SP

Participação por Vídeo - Conferência

Aprovado  Reprovado

Dr. Yosio Edemir Shimabukuro

  
\_\_\_\_\_  
Orientador(a) / INPE / São José dos Campos - SP

Participação por Vídeo - Conferência

Aprovado  Reprovado

Dr. Luiz Eduardo Oliveira e Cruz de  
Aragão

  
\_\_\_\_\_  
Membro da Banca / INPE / São José dos Campos - SP

Participação por Vídeo - Conferência

Aprovado  Reprovado

Dr. Fábio Guimarães Gonçalves

  
\_\_\_\_\_  
Convidado(a) / CANOPY RSS / Biguaçu - SC

Participação por Vídeo - Conferência

Aprovado  Reprovado

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 25 de julho de 2018



*“Conhecimento não é aquilo que você sabe, mas o que você faz com aquilo que você sabe.”*

*Aldous Huxley*



## **AGRADECIMENTOS**

Agradeço primeiramente a minha família, em especial aos meus pais, por todo o apoio concedido durante o período do mestrado, por toda a dedicação, atenção, carinho e amor. Eu não chegaria até aqui se não fosse por vocês.

Sou grato ao meu orientador Prof. Dr. Yosio Edemir Shimabukuro pela disposição em me orientar durante a realização deste trabalho. Por todas suas considerações, sugestões e principalmente por compartilhar conhecimento durante esta etapa.

Agradeço ao Instituto Nacional de Pesquisas Espaciais pela oportunidade de realizar o mestrado.

Agradeço a CAPES pela bolsa de mestrado concedida durante a realização do curso.

Agradeço aos colegas de turma com os quais compartilhei momentos de sofrimento, de alegria e de conquistas no decorrer do curso.

Agradeço ao Bruno e ao Alindomar, fiéis parceiros de república, por todos os momentos que passamos juntos, alegrias, risos e momentos de descontração, os quais foram muito importantes durante esta etapa.

Agradeço a FAPESP pelo financiamento da campanha de campo (Nº processo: 2016/19806-3).

Agradeço ao Anderson, Egídio, Kaio, Valdete e Reginaldo pelo trabalho de campo realizado.

Agradeço ao identificador botânico, Zé Piva, e ao auxiliar de campo, João Piva, que participaram da campanha de campo e dividiram suas experiências e conhecimentos.

Agradeço ao Fabio Gonçalves pelas inúmeras sugestões e suporte, que foram de suma importância para a realização deste trabalho.

Agradeço a Yhasmin, pelo apoio, incentivo e suporte durante a fase final da elaboração deste trabalho.

Agradeço aos Projetos Paisagens Sustentáveis e EBA por disponibilizar os dados LiDAR.

Por fim, mas não menos importantes, agradeço a todos aqueles que não mencionei diretamente, mas contribuíram para a realização deste trabalho.



## RESUMO

A Floresta Amazônica brasileira tem passado por um intenso processo de desmatamento (corte raso) e degradação florestal, que afeta de forma direta os estoques de carbono deste ecossistema. Os processos de degradação podem ser causados por distúrbios naturais e/ou antrópicos, e podem variar em extensão, severidade, qualidade, origem e frequência. Enquanto o desmatamento causa efeitos colaterais diretos na floresta Amazônica, os efeitos derivados da degradação florestal ocorrem de maneira mais gradual, afetando de maneira persistente as condições estruturais e de serviços ecossistêmicos. No ecossistema Amazônico as estimativas de emissões de carbono ainda divergem na literatura. Isto ocorre principalmente pela limitação da disponibilidade de dados sobre a estrutura florestal. Uma alternativa para aquisição de dados estruturais da floresta é a utilização de tecnologias *Light Detection and Ranging* (LiDAR). Neste sentido, a integração entre dados de sensoriamento remoto orbitais com LiDAR pode providenciar novas abordagens para geração de informações sobre a distribuição de áreas degradadas na Amazônia, bem como, o desenvolvimento de novos métodos e modelos que permitam acessar informações sobre modificações estruturais da floresta (p. ex. biomassa) em áreas degradadas. O objetivo geral deste trabalho foi realizar a integração de dados de sensoriamento remoto orbital (Landsat) e LiDAR multitemporais para geração de mapas de biomassa aérea viva e total em áreas degradadas da Floresta Amazônica no estado do Mato Grosso para os anos 2000 e 2017. Além disto, foi realizada uma comparação com mapas de biomassa atualmente disponíveis na literatura. Para quantificar a biomassa nesta área, testou-se como variáveis independentes, índices de vegetação, razões entre bandas, dados de textura (*Grey Level Co-occurrence Matrix – GLCM*) e imagens frações derivadas do Modelo Linear de Mistura Espectral (MLME). Os resultados mostraram que a integração dos dados permite boas estimativas de biomassa em áreas de florestas degradadas. O estoque de biomassa para o ano de 2017 do bioma Amazônia no estado do Mato Grosso, apresentou 4,41 Tg com média de 155,12 Mg/ha  $\pm$  44,91 Mg/ha. Entre os 17 anos, as maiores modificações foram encontradas na classe de 0 a 50 Mg/ha, sendo que, nesta classe é onde estão as áreas afetadas pelo desmatamento (biomassa = 0 Mg/ha). A integração entre dados LiDAR com imagens Landsat proporcionou a elaboração de modelos genéricos que permitem a aplicação em diferentes datas. Além disso, consegue explicar cerca de 47% da variação da biomassa total na região analisada.

Palavras-chave: Amazônia. Biomassa. Floresta Degradada. LiDAR. Sensoriamento Remoto.

# FOREST BIOMASS ESTIMATIVE IN MATO GROSSO STATE FROM LIDAR AND LANDSAT DATA

## ABSTRACT

The Brazilian Amazonian Forest has undergone an intense process of deforestation (forest clearing) and forest degradation, which directly affects the carbon stocks of this ecosystem. The degradation processes may be caused by natural and/or anthropogenic disturbances, and may vary in extent, severity, quality, origin and frequency. While deforestation causes direct effects in the Amazon rainforest, the effects of forest degradation occur gradually, affecting persistently the structural conditions and ecosystem services. In the Amazon ecosystem, estimates of carbon emissions still diverge in the literature. This is mainly due to the limited availability of data on the forest structure. An alternative for the acquisition of forest structural data is the use of Light Detection and Ranging (LiDAR) technologies. In this sense, the integration of orbital remote sensing data with LiDAR can provide new approaches for the generation of information on the distribution of degraded areas in the Amazon, as well as the development of new methods and models that allow access to information on structural modifications of the forest (e.g. biomass) in degraded areas. The main objective of this work was to integrate multitemporal orbital remote sensing (Landsat) and LiDAR data for the generation of live and total aerial biomass maps in degraded areas of the Amazon Forest in the state of Mato Grosso for the years 2000 and 2017. In addition, a comparison was made with biomass maps currently available in the literature. To quantify the biomass in this area, independent variables as vegetation indices, inter-band ratios, texture data (Gray Level Co-occurrence Matrix (GLCM) and images derived from the Linear Spectral Mixture Model (LSMM) were tested as independent variables. The results showed that data integration allows good estimates of biomass in degraded forest areas. The biomass stock for the year 2017 of the Amazon biome in the state of Mato Grosso, presenting 4.41 Tg with a mean of 155.12 Mg/ha  $\pm$  44.91 Mg/ha. Among the 17 years, the greatest changes were found in the class from 0 to 50 Mg/ha, and in this class are the areas affected by deforestation (biomass = 0 Mg/ha). The integration of LiDAR data with Landsat images provided the elaboration of generic models that allow the application in different dates. In addition, it can explain about 47% of the total biomass variation in the analyzed region.

Keywords: Amazon. Biomass. Degraded Forest. LiDAR. Remote Sensing

## LISTA DE FIGURAS

	<b><u>Pág.</u></b>
Figura 2.1 - Esquema do sistema LiDAR aerotransportado. ....	8
Figura 3.1 - Localização da área de estudo. ....	21
Figura 3.2 - Classificação climática para o estado do Mato Grosso. ....	23
Figura 3.3 - Mapa de solos para a área de estudo. ....	23
Figura 3.4 - Fitofisionomias na área de estudo. ....	25
Figura 3.5 - Imagem SRTM do relevo na área de estudo. ....	26
Figura 3.6 - Área de coleta dos dados de campo no Mato Grosso pelo Projeto Paisagens Sustentáveis. ....	28
Figura 3.7 - Esquema demonstrando a alocação da parcela de campo. ....	30
Figura 3.8 - Localização das parcelas de inventário coletadas na campanha de campo. ....	32
Figura 3.9 - Localização dos voos LiDAR realizados no estado do Mato Grosso pelo projeto Paisagens Sustentáveis e pelo projeto EBA. ....	44
Figura 3.10 - Fluxograma do processamento dos dados LiDAR. ....	48
Figura 3.11 - Parte da nuvem de pontos perfilada e ruído dentro dos círculos vermelhos presente nos dados LiDAR após a aplicação do filtro. ....	50
Figura 3.12 - Perfil da nuvem de pontos. ....	51
Figura 3.13 - Fluxograma de processos realizados nas imagens orbitais. ....	53
Figura 3.14 - Fluxograma da metodologia de trabalho. ....	57
Figura 4.1 - Curva de acumulação de espécies em relação ao número de parcelas amostradas. ....	59
Figura 4.2 - Distribuição dos indivíduos por classes de diâmetro. ....	60
Figura 4.3 - Distribuição da biomassa nas áreas sobrevoadas para aquisição dos dados. ....	63
Figura 4.4 - Exemplo de parcela degradada por fogo e por corte seletivo juntamente com o recorte da nuvem de pontos LiDAR. ....	64
Figura 4.5 - Resíduo para os modelos preditores da biomassa acima do solo total e viva. ....	70

Figura 4.6 - Validação LOO para os modelos de biomassa acima do solo total e viva.....	71
Figura 4.7 - Relação entre a biomassa aérea acima do solo total e as variáveis que compõem o modelo preditor.....	72
Figura 4.8 - Relação da biomassa aérea acima do solo viva com as variáveis que compõem o modelo.....	73
Figura 4.9 - Biomassa estimada para o bioma Amazônia no estado do Mato Grosso.....	75
Figura 4.10 - Comparação com os mapas de biomassa elaborado por Saatchi et al. (2011) e Baccini et al. (2017).....	77
Figura 4.11 - Distribuição da biomassa total acima do solo para o bioma Amazônia no estado do Mato Grosso para o ano de 2017. ....	78

## LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 - Características dos sensores a bordo dos satélites Landsat. ....	9
Tabela 2.2 - Índices de vegetação encontrados na literatura utilizados para caracterização da vegetação.....	13
Tabela 3.1 - Características da aquisição dos dados LiDAR nas áreas voadas pelo Projeto Paisagens Sustentáveis no estado do Mato Grosso. ....	34
Tabela 3.2 - Características resumidas da aquisição dos dados LiDAR do projeto EBA. ....	45
Tabela 3.3 - Data de aquisição dos dados LiDAR e das imagens Landsat. ....	46
Tabela 4.1 - Descritores fitossociológicos para as dez espécies com maior Valor de Importância (em ordem decrescente). ....	60
Tabela 4.2 - Correlação de Pearson entre as variáveis Landsat e a biomassa total. ....	65
Tabela 4.3 - Correlação de Pearson entre as variáveis Landsat e a biomassa viva. ....	66
Tabela 4.4 - Valores obtidos a partir dos modelos gerados para prever a biomassa com os dados orbitais. ....	67
Tabela A.1 - Descritores fitossociológicos para todas as espécies presente em campo. ....	98
Tabela A.2 - Índice de Morisita e tipo de distribuição para cada espécie. ....	104



## LISTA DE SIGLAS E ABREVIATURAS

APP	Área de Preservação Permanente
ASCII	<i>American Standard Code for Information Interchange</i>
BAST	Biomassa Acima do Solo Total
BASV	Biomassa Acima do Solo Viva
BNDES	Banco Nacional do Desenvolvimento
CAD	<i>Computer-Aided Design</i>
CAP	Circunferência a Altura do Peito (CAP)
DAP	Diâmetro a Altura do Peito
DEGRAD	Monitoramento da Degradação Florestal na Amazônia Brasileira
DBM	Densidade Básica da Madeira
DGPS	<i>Differential Global Positioning System</i>
EBA	Estimativa de Biomassa na Amazônia
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
FUNCATE	Fundação de Ciência, Aplicações e Tecnologia Espaciais
GLCM	<i>Grey Level Co-occurrence Matrix</i>
GPS	<i>Global Positioning System</i>
INPE	Instituto Nacional de Pesquisas Espaciais
IMU	<i>Inertial Measurement Unity</i>
LaSRC	<i>Landsat Surface Reflectance Code</i>
LEDAPS	<i>Landsat Ecosystem Disturbance Adaptive Processing System</i>
LiDAR	<i>Light Detection and Ranging</i>
LOO	<i>Leave One Out</i>
MAS	Monitoramento Ambiental por Satélite no Bioma Amazônico
MDT	Modelo Digital de Terreno
MLME	Modelo Linear de Mistura Espectral
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
MSS	<i>Multispectral Scanner</i>
OLI	<i>Operational Land Imager</i>
PRODES	Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite

RBV	<i>Return Beam Vidicon</i>
SIG	Sistema de Informação Geográfica
TCHM	<i>Top Canopy Height Model</i>
TIFF	<i>Tagged Image File Format (TIFF)</i>
TIN	<i>Triangulated Irregular Network</i>
TM	<i>Thematic Mapper</i>
USFS	<i>United States Forest Service</i>
USAID	<i>United States Agency for International Development</i>
USGS	<i>United States Geological Survey</i>
VIF	<i>Variance inflation factor</i>

## SUMÁRIO

	<b><u>Pág.</u></b>
1 INTRODUÇÃO .....	1
1.1 Objetivos .....	4
2 Fundamentação Teórica .....	5
2.1 Degradação florestal na Amazônia .....	5
2.2 Light Detection and Ranging – LiDAR.....	6
2.3 Dados de sensoriamento remoto orbital - Landsat.....	8
2.4 Processamento digital de imagens .....	10
2.4.1 Textura.....	10
2.4.2 Índices de vegetação .....	12
2.4.3 Modelo Linear de Mistura Espectral.....	14
2.5 Estimativa de biomassa florestal .....	15
3 MATERIAIS E MÉTODOS .....	21
3.1 Área de estudo.....	21
3.1.1 Clima.....	22
3.1.2 Solos.....	23
3.1.3 Vegetação.....	24
3.1.4 Relevo.....	26
3.2 Materiais.....	26
3.2.1 Dados de campo .....	27
3.2.1.1 Paisagens Sustentáveis.....	27
3.2.1.2 Caracterização da campanha de campo.....	29
3.2.2 Dados LiDAR .....	32
3.2.2.1 Paisagens Sustentáveis.....	33
3.2.2.2 Projeto Estimativa de Biomassa na Amazônia (EBA) .....	44
3.2.3 Imagens orbitais ópticas .....	45
3.3 Métodos .....	47
3.3.1 Caracterização florística e estrutural.....	47
3.3.2 Processamento dos dados LiDAR .....	47

3.3.3	Processamento das imagens ópticas.....	52
3.3.3.1	Modelo Linear de Mistura Espectral.....	53
3.3.3.2	Índices de vegetação .....	54
3.3.3.3	Medidas de textura.....	55
3.3.4	Modelagem da biomassa florestal a partir dos dados orbitais .....	56
3.3.5	Comparação com os mapas de biomassa já existentes .....	57
4	RESULTADOS E DISCUSSÃO .....	58
4.1	Caracterização florístico-estrutural.....	58
4.2	Estimativa de biomassa a partir dos dados LiDAR .....	61
4.3	Análises de correlação entre as métricas derivadas das imagens Landsat e a biomassa estimada com os dados LiDAR.....	64
4.4	Modelagem da biomassa .....	66
4.5	Comparação com mapas de biomassa já publicados na literatura .....	74
4.6	Geração do mapa de biomassa para 2017 .....	78
5	CONSIDERAÇÕES FINAIS .....	80
	REFERÊNCIAS BIBLIOGRÁFICAS .....	83
	APÊNDICE A – TABELA COM OS DESCRITORES FITOSSOCIOLÓGICOS COM TODAS AS ESPÉCIES MENSURADAS A CAMPO .....	98

## 1 INTRODUÇÃO

As florestas tropicais totalizam cerca de 30% das espécies de fauna e flora do planeta (MAUÉS; OLIVEIRA, 2010). Devido a sua grande extensão e sua influência nos regimes climáticos regionais e globais, a Floresta Amazônica é considerada um importante componente do sistema terrestre, desempenhando um papel fundamental na regulação do clima e no balanço de carbono planetário (MYERS et al., 2000; BETTS et al., 2008; MARENGO et al., 2011).

Na Amazônia brasileira, cuja área representa um terço das florestas tropicais do mundo, cerca de 50% da biomassa florestal é constituída por carbono (BROWN et al., 1992; HIGUCHI.; CARVALHO-JR, 1994; LOARIE et al., 2009). No entanto, a Floresta Amazônica tem passado por um intenso processo de desmatamento e degradação florestal, os quais alteram diretamente os estoques de carbono daquele ecossistema.

O desmatamento da Amazônia vem sendo mapeado anualmente desde 1988 pelo Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite (PRODES) desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE), o qual fornece informações importantes sobre a dinâmica espacial e temporal do desmatamento para a Amazônia Legal. No entanto, dados ou mapeamentos da degradação florestal sobre a Amazônia brasileira ainda são escassos.

Mais recentemente o INPE desenvolveu o sistema DEGRAD (Monitoramento da Degradação Florestal na Amazônia Brasileira), com o objetivo de mapear áreas em processo de desmatamento onde a cobertura florestal ainda não foi totalmente removida, ou áreas onde ocorre a presença de corte seletivo (INPE, 2015). Este projeto avança na contribuição dos estudos de degradação da Amazônia, porém limita sua abordagem exclusivamente para os anos de 2007 a 2013.

O conceito de degradação florestal utilizado neste trabalho segue os preceitos da Organização das Nações Unidas para Alimentação e Agricultura (FAO,

2011), o qual envolve os processos de mudança na cobertura florestal que afetam negativamente a estrutura ou a capacidade de fornecer serviços ecossistêmicos. Os processos de mudanças podem ser causados por distúrbios naturais e/ou antrópicos, e podem variar em extensão, severidade, qualidade, origem e frequência. Estes distúrbios são caracterizados por causas naturais (p.ex. fogo, tempestade ou secas) e/ou antrópicas (p.ex. corte seletivo) (FAO, 2011).

Enquanto o desmatamento causa efeitos colaterais diretos na floresta Amazônica, os efeitos derivados da degradação florestal ocorrem de maneira mais gradual, afetando de maneira persistente as condições estruturais e de serviços ecossistêmicos de uma floresta (FOLEY et al., 2016). O desenvolvimento de técnicas e abordagens para detecção e mapeamento de áreas degradadas se constitui um processo mais complexo, porém necessário para o devido entendimento de como as áreas degradadas afetam a dinâmica florestal no ecossistema Amazônico.

Estudos recentes apontam que as emissões brutas derivadas do fogo na Amazônia contribui com cerca de  $989 \pm 504 \text{ Tg CO}_2 \text{ ano}^{-1}$  (ARAGÃO et al., 2018). No entanto, estimativas oficiais de carbono no Brasil ainda não levam em consideração as emissões derivadas dos processos de degradação florestal, contabilizando somente aqueles derivados do desmatamento (BERENQUER et al., 2014).

Alguns estudos quantificando as emissões de carbono em áreas degradadas indicam que a degradação florestal é subestimada e generalizada nos trópicos, e que áreas degradadas podem, na verdade, cobrir uma área similar ou superior as áreas já desmatadas (ASNER et al., 2010; ZHURAVLEVA et al., 2013; PEARSON et al., 2014). Mais recentemente Baccini et al. (2017) mapearam os fluxos de carbono na região tropical e encontraram que a degradação representa aproximadamente 70% das emissões. O desenvolvimento de metodologias para o mapeamento da biomassa florestal em áreas degradadas é de suma importância, pois fornecem informações que

podem auxiliar na compreensão da dinâmica florestal e dos fluxos de carbono. Essas informações podem contribuir diretamente no melhoramento das estimativas de estoque de carbono para a região Amazônica e auxiliar nos modelos climáticos globais e na implementação de políticas públicas de conservação das florestas, mantendo a função ecológica do ecossistema (ARAGÃO et al., 2014).

Em florestas tropicais, a biomassa florestal pode variar em função das tipologias florestais, da localização espacial e do tempo (HOUGHTON et al., 2012). As informações obtidas a partir da estimativa da biomassa permitem determinar se o local atua como fonte ou sumidouro de carbono, bem como sua intensidade e dinâmica. No ecossistema Amazônico, as estimativas de emissões de carbono ainda divergem na literatura (OMETTO et al., 2014). Isto ocorre principalmente pela limitação da disponibilidade de dados sobre a estrutura florestal (RAMÍREZ, 2015) e pelas diferentes metodologias adotadas.

Uma alternativa para aquisição de dados estruturais da floresta é a utilização de tecnologias inovadoras, como o *Light Detection and Ranging* (LiDAR). As informações coletadas a partir de sensores LiDAR permite realizar medições diretas dos atributos tridimensionais da estrutura vertical da floresta, e podem ser adquiridos a nível terrestre, aerotransportado e orbital (SUN et al., 2008; WULDER et al., 2012).

Esta ferramenta apresenta um grande potencial para detecção e obtenção de informação sobre a estrutura florestal de áreas degradadas (D'OLIVEIRA et al., 2012; ELLIS et al., 2016; LONGO et al., 2016). Estas áreas apresentam um padrão de mudança estrutural da floresta diferente daquele derivado de um processo de desmatamento (SHIMABUKURO et al., 2014; JOSHI et al., 2015; SATO et al., 2016). No caso da degradação, esta pode ser “visível” através de modificações estruturais dos dosséis florestais, reduzindo camadas de dossel de sistemas estruturalmente diversos e impactando na estratificação do sistema florestal, ao invés de perda total da cobertura florestal encontrada num

processo de desmatamento. No entanto, a disponibilidade de dados LiDAR sobre grandes extensões de áreas ainda se apresenta como uma limitação.

Neste sentido, a devida integração entre dados de sensoriamento remoto orbitais com a tecnologia LiDAR podem providenciar novas abordagens para geração de informações sobre a distribuição de áreas degradadas na floresta Amazônica, bem como, o desenvolvimento de novos métodos e modelos que permitam acessar informações sobre modificações estruturais da floresta (p. ex. biomassa) em áreas degradadas.

### **1.1 Objetivos**

O objetivo geral deste trabalho foi realizar a integração de dados de sensoriamento remoto orbital (Landsat), dados LiDAR e dados de campo em diferentes escalas para geração de mapas de biomassa aérea viva e total em áreas de Floresta Amazônica remanescentes no estado do Mato Grosso para os anos de 2000 e 2017, bem como comparar os mapas gerados com os mapas de biomassa atualmente disponíveis na literatura.

Para atingir o objetivo geral, foram definidos os seguintes objetivos específicos:

- Analisar a estrutura e composição da floresta a partir dos dados de campo;
- Calibrar uma equação para estimativa de biomassa florestal a partir de imagens orbitais Landsat ;
- Verificar se a variação espectral das imagens orbitais causa uma variação na estimativa da biomassa em área degradada;
- Estimar o estoque de biomassa em 2000 e 2017 no bioma Amazônico no estado do Mato Grosso;
- Comparar os resultados obtidos pelo método proposto com os mapas de biomassa atualmente disponíveis na literatura.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Degradação florestal na Amazônia

Induzida por políticas governamentais, a expansão das atividades agrícolas na Amazônia teve início na década de 1960, incentivadas pela dedução do imposto de renda, preços dos terrenos baixos ou até mesmo doados (DIAS-FILHO, 2015). Desde então, a conversão das áreas de floresta em função do avanço da pecuária ou agricultura tem se intensificado na região (MORAN et al., 1994; GALFORD et al., 2010). O desmatamento na Amazônia Legal em 2017 foi de aproximadamente 6.624 km<sup>2</sup>, sendo no estado do Mato Grosso, a segunda maior taxa de desmatamento com cerca de 1.341 km<sup>2</sup> (20,2%), superado somente pelo estado do Pará com 2.413 km<sup>2</sup> (36,4%) (INPE, 2017).

Os eventos de desmatamento e degradação por fogo e corte seletivo alteram a dinâmica e o fluxo de carbono do ambiente, principalmente com a expressiva participação da Amazônia na regulação do clima e balanço de carbono global. Entre os anos 2000 e 2010 o total de emissões de carbono causadas pela perda de biomassa acima e abaixo do solo devido ao desmatamento no Brasil foi de  $143 \pm 56 \text{ Tg C ano}^{-1}$  (SONG et al., 2015). Grande parte dessa perda encontra-se na região amazônica e é fruto dos processos de alteração do uso do solo, o qual contribuiu com as emissões de CO<sub>2</sub>, em torno de 150 Tg C em 2009, considerando o balanço da floresta primária e secundária, o que representa cerca de 12,5% das emissões globais (1.200 Tg C) (LE QUÉRÉ et al., 2009).

A detecção de mudanças é um processo que identifica as alterações em um ambiente observando-o ao longo do tempo. Os dados de sensoriamento remoto possibilitam o monitoramento das mudanças na estrutura florestal devido ao seu caráter sinóptico e frequente. Diversos estudos têm sido realizados de modo a correlacionar esses dados com variáveis biofísicas.

Carreiras et al. (2002) utilizaram imagens fração derivadas do Modelo Linear de Mistura Espectral (MLME) do sensor SPOT-4 *Vegetation* para avaliar

mudanças na cobertura da terra no estado do Mato Grosso. Anderson et al. (2005) mapearam a cobertura vegetal do estado do Mato Grosso usando dados multitemporais do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS).

Os dados dos sensores a bordo dos satélites Landsat tem sido utilizados amplamente para a detecção, monitoramento e avaliação da degradação da floresta Amazônica. Principalmente eventos oriundos de corte seletivo (ASNER et al., 2002; MATRICARDI et al., 2010; SHIMABUKURO et al., 2014) e fogo (MORTON et al., 2011; LIMA et al., 2012; ALENCAR et al., 2015; SHIMABUKURO et al., 2017). Além disso, a tecnologia LiDAR tem auxiliado na obtenção de informações e caracterização da vegetação em áreas degradadas (D'OLIVEIRA et al., 2012; ANDERSEN et al., 2014; LONGO et al., 2016)

## **2.2 Light Detection and Ranging – LiDAR**

O LiDAR consiste em uma técnica de sensoriamento remoto ativo, o qual está baseado na mensuração do intervalo de tempo entre a emissão de um pulso de energia e o retorno deste até o sensor (DUBAYAH; DRAKE, 2000; DRAKE; DUBAYAH; CLARK et al., 2002). O sensor emite pulsos de energia em direção ao objeto, os quais interagem com a matéria e são por ela refletidos e retornam ao sensor, que mede com precisão o tempo entre a emissão e a recepção do pulso. Com base no intervalo de tempo entre a emissão-recepção do pulso e a velocidade da luz, pode-se calcular a distância entre o sensor e o alvo e a partir disso, realizando o processamento dos dados, é possível obter a altura de determinado objeto presente na superfície terrestre (KUMAR, 2012).

Ao acoplar o sensor LiDAR em um avião, também se utiliza uma Unidade de Medida Inercial (*Inertial Measurement Unity – IMU*), o qual é capaz de registrar qualquer variação que possa ocorrer na velocidade e nas orientações x, y e z da aeronave, denominadas rolagem, arfagem e guinada, respectivamente (Figura 2.1). Além deste equipamento, também se utiliza o Sistema de Posicionamento Global Diferencial (*Differential Global Positioning System – DGPS*), neste caso, dois equipamentos são utilizados, um a bordo do avião e

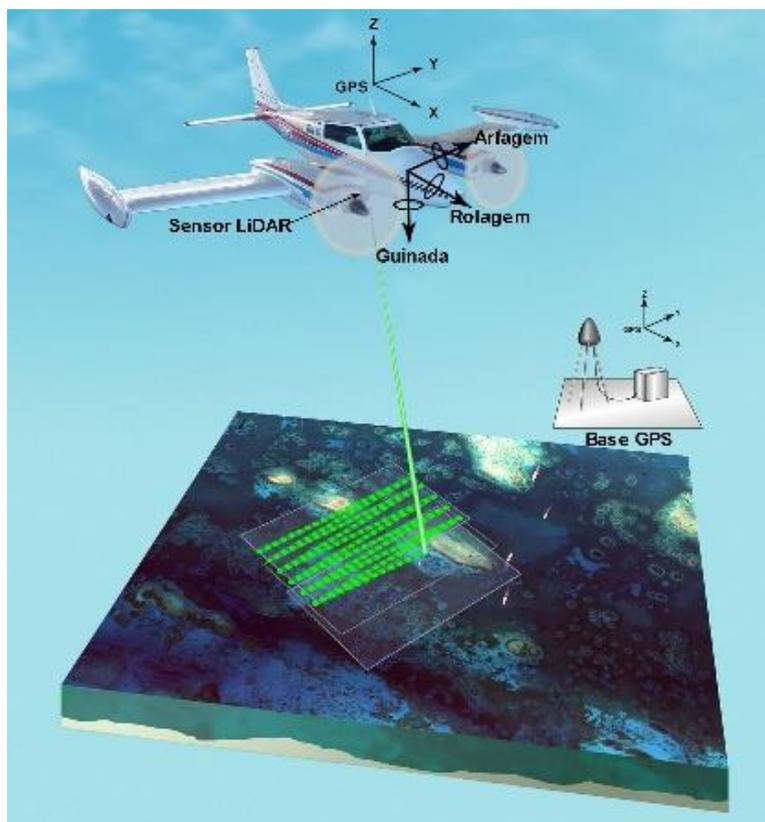
outro na superfície (Figura 2.1) para que seja possível registrar com precisão a localização de cada pulso emitido pelo sensor.

O pulso emitido para a aquisição dos dados consiste na emissão da energia eletromagnética na faixa do infravermelho, de 1040 a 1060 nm (JENSEN, 2009). Porém em estudos batimétricos, onde se necessita uma maior penetrabilidade do pulso, pode-se utilizar um comprimento de onda menor, por exemplo, a faixa espectral do verde (530 nm). E mais recentemente, estudos com LiDAR multiespectral tem sido desenvolvidos, onde são emitidos pulsos em mais de um comprimento de onda (NIU et al., 2015; CHEN et al., 2017).

Os sensores LiDAR coletam a distribuição tridimensional das copas das árvores, bem como a topografia e o sub-bosque, viabilizando a estimativa da altura da vegetação, da cobertura e estrutura do dossel (LEFSKY et al., 2002). Além disso, permitem a quantificação de biomassa, volume, área basal e densidade de árvores (MEANS et al., 2000), apresentando alta correlação na obtenção das métricas florestais (HYYPÄ et al., 2008; NÆSSET, 2011; STEPHENS et al., 2012). Dessa maneira, apresentando alto potencial para aplicações florestais (LEFSKY et al., 2002; NÆSSET; GOBAKKEN, 2008; HUDAK et al., 2009).

Andersen et al. (2014) utilizaram dados LiDAR para quantificar a biomassa na Amazônia ocidental e também avaliaram o impacto da extração seletiva de madeira. Os autores conseguiram identificar estradas, trilhas de arraste, clareiras e pátio de estocagem na área de estudo. Longo et al. (2016) quantificaram a biomassa aérea de floresta degradada na Amazônia brasileira a partir de dados LiDAR. Gonçalves et al. (2017) estimaram a biomassa acima do solo na Floresta Nacional do Tapajós e investigaram as incertezas associadas a estimativas de biomassa em nível de parcela adquiridas especificamente para calibrar medidas de sensoriamento remoto em florestas tropicais. Em adição aos dados LiDAR, dados de sensoriamento remoto orbital auxiliam no processo de estimativa da biomassa em florestas tropicais.

Figura 2.1 - Esquema do sistema LiDAR aerotransportado.



Fonte: Adaptado de USGS (2006).

### 2.3 Dados de sensoriamento remoto orbital - Landsat

A família de satélites Landsat começou a coletar dados da superfície da Terra na década de 70. O lançamento do Landsat 1, que levava a bordo dois sensores, *Return Beam Vidicon* (RBV) e *Multispectral Scanner* (MSS) com resolução espacial de 68 m x 83m, operou até 1978. Em 1975 o Landsat 2 foi lançado possuindo os mesmos sensores que o seu antecessor e obteve imagens durante sete anos (USGS, 2017).

Em 1978 foi lançado o Landsat 3 com duas câmeras RCA e os sensores RBV e MSS, sendo que este último sofreu uma alteração na resolução espacial para 38 m. O seu sucessor, o Landsat 4, foi lançado em 1982 e tinha a bordo o sensor MSS e o *Thematic Mapper* (TM) (USGS, 2017). O sensor TM possui sete bandas espectrais e resolução radiométrica de 8 bits. O Landsat 5 foi lançado em 1985 com os mesmos sensores que o Landsat 4 e encerrou sua

operação somente em 2011. O sucessor, Landsat 6, não entrou em órbita. Em 1999 o Landsat 7 foi lançado com o sensor *Enhanced Thematic Mapper Plus* (ETM+), que reproduzia as características do sensor TM. Este satélite ainda está em operação, mas desde 2003 apresenta falhas (*Scan Line Corrector Failed*).

O Landsat 8 foi lançado em 2013 e apresenta dois sensores o *Operational Land Imager* (OLI) e o *Thermal Infrared Sensor*. Apresenta resolução temporal de 16 dias e resolução radiométrica de 12 bits. Para 2020 está previsto o lançamento do Landsat 9 (USGS, 2017). As características dos sensores a bordo dos satélites Landsat estão resumidas na Tabela 2.1.

Tabela 2.1 - Características dos sensores a bordo dos satélites Landsat.

Sensor Landsat	LS 1-3 RBV (nm)	LS 1-5 MSS (nm)	LS 4-5 TM (nm)	LS 7 ETM+ (nm)	LS 8 OLI (nm)
Coastal aerosol	-	-	-	-	B1 (0,43-0,45)
Blue	B1 (0,48-0,57)	-	B1 (0,45-0,52)	B1 (0,45-0,52)	B2 (0,45-0,51)
Green	-	B1 (0,5-0,6)	B2 (0,52-0,60)	B2 (0,52-0,60)	B3 (0,53-0,59)
Red	B2 (0,58-0,68)	B2 (0,6-0,7)	B3 (0,63-0,69)	B3 (0,63-0,69)	B4 (0,64-0,67)
NIR 1	B3 (0,7-0,83)	B3 (0,7-0,8)	-	-	-
NIR 2	-	B4 (0,7-1,1)	B4 (0,76-0,90)	B4 (0,77-0,90)	B5 (0,85-0,88)
SWIR 1	-	-	B5 (1,55-1,75)	B5 (1,55-1,75)	B6 (1,57-1,65)
SWIR 2	-	-	B7 (2,08-2,35)	B7 (2,09-2,35)	B7 (2,11-2,29)
Thermal	-	-	B6 (10,40-12,50)	B6 (10,40-12,50)	B10 (10,60-11,19) B11 (11,50-12,51)
Pan-Chromatic	-	-	-	B8 (0,52-0,90)	B8 (0,50-0,68)
Cirrus	-	-	-	-	B9 (1,36-1,38)

Fonte: Adaptado de Young et al. (2017).

O Serviço Geológico dos Estados Unidos (*United States Geological Survey – USGS*) é o responsável pelo recebimento e distribuição das imagens provenientes dos sensores a bordo dos satélites Landsat. As imagens são disponibilizadas em diferentes níveis de processamento, como o produto “*Landsat Surface Reflectance Level-2 Science Products*” em que cada *pixel* está convertido para valor de reflectância de superfície. A correção atmosférica do Landsat 4-7 é baseada no modelo 6S (*Second Simulation of the Satellite Signal in the Solar Spectrum*) e no algoritmo *Landsat Ecosystem Disturbance Adaptive Processing System* (LEDAPS) enquanto que para o Landsat 8 a

correção atmosférica é baseada no *Landsat Surface Reflectance Code* (LaSRC).

## 2.4 Processamento digital de imagens

### 2.4.1 Textura

A textura se refere ao padrão da variação na intensidade dos níveis de cinza de uma imagem (LU; BATISTELLA, 2005), e dessa maneira, as imagens de textura podem identificar diferenças nos aspectos da estrutura da floresta, incluindo idade, densidade e índice de área foliar (CHAMPION et al., 2008).

Os dados de textura podem ser divididos a partir da soma e diferença de histograma (UNSER, 1986) e, segundo Haralick et al. (1973) a partir da Matriz de Coocorrência de Nível de Cinza (*Grey Level Co-occurrence Matrix* – GLCM).

A GLCM é uma matriz quadrada de dimensão igual a resolução radiométrica da imagem, que contém a frequência das ocorrências dos *pixels* a partir das combinações entre dois *pixels* em uma determinada direção, expressa por ângulos (0°, 45°, 90°, 135°, ...) e uma distância D, medida em pixels.

Uma das aplicações da GLCM é utilizar uma janela móvel, de tamanho pré-definido, para caracterizar texturas em uma imagem. Essa caracterização é realizada através de um conjunto de estatísticas a cada deslocamento da janela ao longo de diferentes direções (SARKER; NICHOL, 2011). Dentre as medidas de texturas GLCM pode-se mencionar algumas, como:

Média (ME): É o valor médio na dispersão dentro da matriz de coocorrência (Equação 2.1).

$$ME = \sum_{i,j=0}^{N-1} iP_{i,j} \quad (2.1)$$

Variância (VA): Baseia-se na dispersão dos dados numéricos em torno de um valor médio, de valores dentro da matriz de coocorrência (Equação 2.2).

$$VA = \sum_{i,j=0}^{N-1} iP_{i,j}(i - ME)^2 \quad (2.2)$$

Homogeneidade (HO): Assume valores alto quando há pequenas variações entre os *pixels* (Equação 2.3).

$$HO = \sum_{i,j=0}^{N-1} i \frac{P_{ij}}{1 + (i - j)^2} \quad (2.3)$$

Contraste (CO): É uma estimativa das variações locais dos níveis de cinza entre os *pixels* (Equação 2.4).

$$CO = \sum_{i,j=0}^{N-1} iP_{i,j}(i - j)^2 \quad (2.4)$$

Correlação (CR): Avalia o quão correlacionado está um pixel com os seus vizinhos (Equação 2.5).

$$CR = \sum_{i,j=0}^{N-1} iP_{ij} \left[ \frac{(i - ME)(j - ME)}{\sqrt{VA_i VA_j}} \right] \quad (2.5)$$

Segundo Momento Angular (SMA): É a medida da uniformidade da textura (Equação 2.6).

$$SMA = \sum_{i,j=0}^{N-1} iP_{i,j}^2 \quad (2.6)$$

Entropia (EN): Avalia a desordem entre o *pixel* e a vizinhança (Equação 2.7).

$$EN = \sum_{i,j=0}^{N-1} iP_{i,j}(\ln P_{ij}) \quad (2.7)$$

Dissimilaridade (DI): É semelhante a variância, porém difere quanto ao peso, pois deixa de ser exponencial para ser linear (Equação 2.8).

$$DI = \sum_{i,j=0}^{N-1} iP_{i,j}|i-j| \quad (2.8)$$

Onde:  $i, j$  é a linha e coluna;  $P_{ij}$  é o valor na célula  $i, j$  de uma janela móvel;  $N$  é número de linhas e colunas.

Diversos estudos têm sido realizados os quais relacionam dados de textura e biomassa floresta, como por exemplo em floresta tropical densa com imagens de alta resolução espacial (ECKERT, 2012; SARKER; NICHOL, 2013). A correlação entre a biomassa e os dados de textura em diferentes janelas móveis em imagens do sensor TM do satélite Landsat-5 (LU; BATISTELLA, 2005). Dube; Mutanga (2015) investigaram as métricas de textura para estimar biomassa acima do solo a partir de imagens do sensor Landsat-8/OLI em plantios florestais de *Eucaliptus sp* e *Pinus sp* na África do Sul.

#### **2.4.2 Índices de vegetação**

O surgimento dos índices de vegetação ocorreu por volta de 1969 no trabalho desenvolvido por Carl Jordan (JORDAN, 1969), que pretendia realçar a vegetação em relação aos outros alvos contidos em uma área. O primeiro índice desenvolvido foi razão simples (*Simple Ratio*), o qual consiste em uma razão entre as bandas do infravermelho próximo e a banda do vermelho. Em geral, os índices resultam das combinações de duas ou mais bandas espectrais de um determinado sensor e muitas vezes são utilizados para realçar a resposta espectral do objeto de interesse presente na imagem (HUETE et al., 2002).

Geralmente combina-se as bandas espectrais que tenham uma descorrelação ocasionada pela resposta espectral diferente, como no caso do estudo da vegetação, procura-se combinar bandas do visível com bandas do infravermelho próximo (PONZONI et al., 2012). Ainda segundo estes autores, os índices de vegetação podem minimizar o efeito da geometria de aquisição/iluminação e declividade do terreno, e também possibilita reduzir a dimensionalidade dos dados multitemporais (MOREIRA, 2011).

Encontra-se na literatura mais de 50 índices de vegetação (MOREIRA; SHIMABUKURO, 2004), e estes podem ser relacionados com parâmetros biofísicos da vegetação, tais como biomassa, índice de área foliar,

produtividade, porcentagem de cobertura do solo e atividade fotossintética (PONZONI, 2001), auxiliando também no monitoramento das mudanças da vegetação (BANNARI et al., 1995). A Tabela 2.2 apresenta alguns índices de vegetação.

Jin et al. (2014) analisaram a relação entre os índices de vegetação a partir de imagens MODIS e a biomassa no norte da China e obtiveram o melhor resultado quando utilizaram o NDVI, com um R<sup>2</sup> de 0,6 e RMSE de 1,14 Mg/ha.

No trabalho de Hentz et al. (2014), os autores utilizaram índices de vegetação para estimar a biomassa em Floresta Ombrófila Mista no estado do Paraná. Dentre os índices utilizados (NDVI, SAVI e EVI), a equação que utilizava o índice SAVI apresentou os melhores resultados, com R<sup>2</sup><sub>ajus</sub> de 0,86 e S<sub>yx</sub>(%) de 27,9%.

Tabela 2.2 - Índices de vegetação encontrados na literatura utilizados para caracterização da vegetação.

Índice	Equação	Referência
<i>Atmospherically Resistant Vegetation Index (ARVI)</i>	$ARVI = \frac{NIR - [R - \gamma(B - R)]}{NIR + [R - \gamma(B - R)]}$	(KAUFMAN; TANRÉ, 1992).
<i>Difference Vegetation Index (DVI)</i>	$DVI = NIR - R$	(TUCKER, 1979)
<i>Enhanced Vegetation Index (EVI)</i>	$EVI = 2,5 * \frac{NIR - R}{NIR + 6 * R - 7,5 * B + 1}$	(HUETE et al., 2002)
<i>Global Environmental Monitoring Index (GEMI)</i>	$GEMI = \frac{eta(1 - 0,25 * eta) - \frac{R - 0,125}{1 - R}}{2(NIR^2 - R^2) + 1,5 * NIR + 0,5 * R}$ $eta = \frac{NIR + R + 0,5}{NIR + R + 0,5}$	(PINTY; VERSTRAETE, 1992)
<i>Green Atmospherically Resistant Index (GARI)</i>	$GARI = \frac{NIR - [R - \gamma(B - R)]}{NIR + [R - \gamma(B - R)]}$	(GITELSON et al., 1996)
<i>Green Normalized Difference Vegetation Index (GNDVI)</i>	$GNDVI = \frac{NIR - G}{NIR + G}$	(GITELSON.; MERZLYAK, 1998)
<i>Green Vegetation Index (GVI)</i>	$GVI = (-0,2848 * B) + (-0,2435 * G) + (-0,5436 * R) + (0,7243 * NIR) + (0,084 * SW1) + (-0,18 * SW2)$	(KAUTH; THOMAS, 1976)
<i>Infrared Percentage Vegetation Index (IPVI)</i>	$IPVI = \frac{NIR}{NIR + R}$	(CRIPPEN, 1990)

(Continua)

Tabela 2.2 Conclusão

<b>Índice</b>	<b>Equação</b>	<b>Referência</b>
<i>Modified Non-Linear Index (MNLI)</i>	$MNLI = \frac{(NIR^2 - R) * (1 + L)}{NIR^2 + R + L}$	(YANG et al., 2008)
<i>Modified Simple Ratio (MSR)</i>	$MSR = \frac{\left(\frac{NIR}{R}\right) - 1}{\left(\sqrt{\frac{NIR}{R}}\right) + 1}$	(CHEN, 1996)
<i>Non-Linear Index (NLI)</i>	$MLI = \frac{(NIR^2 - R)}{NIR^2 + R}$	(GOEL; QIN, 1994)
<i>Normalized Difference Vegetation Index (NDVI)</i>	$NDVI = \frac{NIR - R}{NIR + R}$	(ROUSE et al., 1973)
<i>Optimized Soil Adjusted Vegetation Index (OSAVI)</i>	$OSAVI = \frac{1,5 * (NIR - R)}{(NIR + R + 0,16)}$	(RONDEAUX et al., 1996)
<i>Renormalized Difference Vegetation Index (RDVI)</i>	$RDVI = \frac{NIR - R}{\sqrt{NIR + R}}$	(ROUJEAN; BREON, 1995)
<i>Soil Adjusted Vegetation Index (SAVI)</i>	$SAVI = \frac{1,5 * (NIR - R)}{IVP + R + 0,5}$	(HUETE, 1988)
<i>Transformed Difference Vegetation Index (TDVI)</i>	$TDVI = \sqrt{0,5 + \frac{NIR - R}{NIR + R}}$	(BANNARI et al., 2002)
<i>Visible Atmospherically Resistant Index (VARI)</i>	$VARI = \frac{G - R}{G + R - B}$	(GITELSON et al., 2002)

Onde: R, G, B, NIR, SW1 e SW2 são as bandas referentes ao vermelho, verde, azul e infravermelho próximo, infravermelho de ondas curtas, respectivamente;  $\gamma$  é igual a 1; L é o fator de ajuste do retorno do dossel igual a 0,5.

Fonte: Produção do autor.

### 2.4.3 Modelo Linear de Mistura Espectral

O Modelo Linear de Mistura Espectral (MLME), proposto por Shimabukuro; Smith, (1991), baseia-se em uma relação linear entre os elementos contidos em um *pixel* (Equação 2.9), onde a radiância registrada no sensor corresponde ao somatório das radiâncias de vários alvos contidos no *pixel*.

A mistura está relacionada com a resolução espacial do sensor. Quanto maior a resolução espacial, menor será a quantidade de componentes com características específicas dentro de um *pixel* (SHIMABUKURO; SMITH, 1991). Com isso, a resposta espectral de cada *pixel* na imagem é uma combinação linear das respostas espectrais dos diversos alvos compreendidos no *pixel*.

$$r_i = \sum_{j=1}^n (a_{ij}x_j) + e_i \quad (2.9)$$

Onde:  $r_i$  é a reflectância espectral para a  $i$ -ésima banda espectral de um *pixel* contendo uma ou mais componentes;  $a_{ij}$  é reflectância espectral do  $j$ -ésimo componente do *pixel* para a  $i$ -ésima banda espectral;  $x_j$  é valor proporcional do  $j$ -ésimo componente do *pixel*;  $e_i$  é erro para a  $i$ -ésima banda espectral;  $j$  é o número de componentes; e  $i$  é o número de bandas espectrais.

O resultado do MLME gera as imagens frações que contém informações sobre a proporção e a resposta espectral de cada componente dentro do pixel. Em termos gerais as componentes são solo, vegetação e sombra/água.

## 2.5 Estimativa de biomassa florestal

A estimativa de biomassa vai desde o tratamento dos dados até o cálculo da biomassa propriamente dita. Dentro do tratamento dos dados, muitas técnicas podem ser empregadas, desde a organização até a obtenção do produto final. Uma delas é a caracterização estrutural da vegetação a partir de dados de campo.

Um ponto importante em levantamentos fitossociológicos é avaliar se a amostragem foi suficiente, pode-se realizar esta avaliação a partir da curva de acumulação de espécies, que é um gráfico utilizado na área de ecologia, que consiste em relacionar o número de espécies (eixo Y) contra a área amostral ou número de parcelas (eixo X). Nos estudos de fitossociologia essa curva é utilizada para saber a intensidade amostral necessária para se representar adequadamente uma comunidade vegetal (MUELLER-DOMBOIS; ELLENBERG, 1974).

A riqueza e a diversidade de espécies dependem, além da própria natureza da comunidade, do esforço amostral despendido, uma vez que o número de espécies aumenta com o aumento do número de indivíduos amostrados. As curvas de acumulação de espécies permitem avaliar o quanto um estudo se aproxima de capturar todas as espécies do local (MUELLER-DOMBOIS; ELLENBERG, 1974). Quando a curva estabiliza, ou seja, nenhuma espécie

nova é adicionada, significa que a riqueza total foi obtida. A partir disso, novas amostragens não são necessárias.

Obtendo-se várias curvas a partir da adição aleatória das amostras pode-se calcular uma curva média. Em todo caso, a estabilização da curva é bastante difícil, pois muitas espécies raras costumam ser adicionadas após muitas amostragens, sobretudo em regiões tropicais. Assim, medidas de riqueza de espécies que permitam estimar a riqueza a partir dos dados obtidos, ou comparar inventários entre diferentes áreas com diferentes unidades amostrais são bastante úteis nestes casos.

A análise da estrutura horizontal da vegetação permite quantificar as espécies analisando a distribuição de cada uma delas. Esta análise pode ser realizada por meio dos descritores fitossociológicos, que podem ser utilizados a nível de família como também a nível de espécie. Segundo Mueller-Dombois; Ellenberg, (1974) os descritores fitossociológicos podem ser definidos como:

Densidade Absoluta (DA): Refere-se ao número de indivíduos de uma mesma espécie por unidade de área (Equação 3.1);

Densidade Relativa (DR): Expressa em porcentagem a contribuição de cada espécie em relação ao total de espécies (Equação 3.2);

Dominância absoluta (DoA): Consiste na soma da área basal de todos os indivíduos da espécie presentes na amostra, por unidade de área (Equação 3.3);

Dominância Relativa (DoR): É a porcentagem entre área basal total de uma determinada espécie e a área basal total por unidade de área (Equação 3.4);

Frequência Absoluta (FA): É uma medida, expressa em porcentagem, que demonstra a ocorrência de uma espécie na comunidade florestal (Equação 3.5);

Frequência Relativa (FR): É a proporção, expressa em porcentagem, entre a frequência absoluta de cada espécie e a frequência absoluta total (Equação 3.6);

Valor de importância (VI): Expressa a posição ecológica da espécie na comunidade analisada (Equação 3.7). Em cada parâmetro que compõe o VI pode-se compreender se a espécie é abundante, qual a distribuição e se ela apresenta área basal grande ou pequena. Dando uma ideia sobre densidade, distribuição espacial e a dimensão alcançada pela espécie em relação às outras (FELFILI; VENTUROLI, 2000)

$$DA_i = \frac{n_i}{A} \quad (3.1) \quad DR_i = 100 * \frac{DA_i}{\sum_{n=1}^S DA_i} \quad (3.2)$$

$$DoA_i = \frac{G_i}{A} \quad (3.3) \quad DoR_i = 100 * \frac{G_i}{\sum_{n=1}^S G_i} \quad (3.4)$$

$$FA_i = 100 * \frac{u_i}{u_t} \quad (3.5) \quad FR_i = 100 * \frac{FA_i}{\sum_{n=1}^S FA_i} \quad (3.6)$$

$$VI = \frac{DR_i + DoR_i + FR_i}{3} \quad (3.7)$$

Em que:  $DA_i, DoA_i, FA_i, DR_i, DoR_i$  e  $FR_i$ : Densidade, Dominância e Frequência Absoluta e Relativa, respectivamente da  $i$ -ésima espécie;  $n_i$ : Quantidade de indivíduos da  $i$ -ésima espécie;  $A$ : Área total (ha);  $S$ : Total de espécies mensuradas;  $G$ : Área basal de  $i$ -ésima espécie ( $m^2$ );  $u_i$ : Quantidade de unidades amostrais que a  $i$ -ésima espécie ocorre;  $u_t$ : Total de unidades amostrais;  $VI$ : Índice do Valor de Importância.

Além dos descritores supracitados, outras medidas podem ser utilizadas para avaliar um povoamento florestal. O índice de Shannon-Wiener (SHANNON; WEAVER, 1949) que é originado da teoria da informação, avalia o grau de incerteza em prever a qual espécie da população um indivíduo pertence se retirado aleatoriamente. Quanto mais espécies existirem e mais homogênea for sua distribuição, maior será a diversidade, e maior o valor do índice.

O índice de Equabilidade de Pielou (PIELOU, 1967) refere-se ao padrão de distribuição dos indivíduos entre as espécies. Seu valor apresenta uma amplitude de 0 a 1, sendo que quanto maior o valor deste índice, significa dizer que as espécies tendem a possuir a mesma quantidade de indivíduos, fazendo com que a dominância ecológica diminua.

Como sugerido por Magurran (1988), aplicou-se técnicas que avaliam a composição florística. Dentre estas, a diversidade de espécies e a dominância ecológica, por meio do índice de Shannon-Wiener ( $H'$ ) (Equação 3.8) e a equabilidade de Pielou ( $J$ ) (Equação 3.9) respectivamente.

$$H' = - \sum_{i=1}^S \left[ \frac{n_i * \ln \left( \frac{n_i}{N} \right)}{N} \right] \quad (3.8)$$

$$J' = \frac{H'}{\ln(S)} \quad (3.9)$$

Onde:  $H'$ : índice de Shannon-Wiener;  $n_i$ : quantidade de indivíduos da espécie  $i$ ;  $N$ : Número total de indivíduos;  $J'$ : Equabilidade de Pielou;  $S$ : Número total de espécies amostradas.

Além do índice de Shannon-Wiener e a Equabilidade de Pielou também é possível caracterizar as espécies presentes em uma determinada área a partir da sua distribuição relativa às espécies mensuradas durante um inventário florestal.

O Índice de Dispersão de Morisita (Equação 3.10) é utilizado para avaliar o padrão de distribuição espacial de indivíduos de espécies arbóreas, quando parcelas são a forma de amostragem utilizadas (MORISITA, 1959a). As distribuições podem ser:

Distribuição agrupada: É aquela em que os indivíduos se encontram formando grupos;

Distribuição aleatória: Está relacionada com as árvores das espécies que têm uma ocorrência rara ou ocasional;

Distribuição regular: As árvores se encontram regularmente distribuídas no terreno.

$$I_{\delta} = q \frac{\sum_{i=1}^q x_i(x_i - 1)}{T(T - 1)} \quad (3.10)$$

Onde:  $q$  é o número de parcelas;  $x_i$  é o número de indivíduos na  $i$ -ésima parcela;  $T$  é

o número de indivíduos na comunidade mensurada.

Além da descrição da estrutura da floresta, a partir dos dados de campo, na modelagem da biomassa, principalmente em grandes extensões de áreas, a utilização de dados provenientes de sensoriamento remoto, como imagens de satélite auxilia nessa estimativa (SAATCHI et al., 2007; GOETZ et al., 2009; SAATCHI et al., 2011) podendo reduzir o erro na estimação (WEISBIN et al., 2011).

Na literatura há alguns mapas de biomassa desenvolvidos para a região pantropical (SAATCHI et al., 2011; BACCINI et al., 2012; 2017; AVITABILE et al., 2016). Os mais utilizados são os de Baccini et al. (2017) e Saatchi et al. (2011). As principais diferenças entre a metodologia utilizada para gerar os dois mapas de biomassa supracitados resumem-se em que no mapa do Saatchi et al. (2011) a resolução espacial é de 1 km, foram utilizadas 493 parcelas de campo, dados MODIS/IAF e NDVI e os autores utilizaram o algoritmo MaxEnt para estimar a biomassa. Enquanto que o mapa de Baccini et al. (2017) é um mapa reprocessado baseado em Baccini et al. (2012) que apresenta uma resolução espacial de 30 m, foram utilizadas 283 parcelas de campo, dados do MODIS BRDF e a biomassa foi estimada usando RandomForest. Além disso, ambos os mapas utilizam dados SRTM e dados LiDAR do GLAS.

Além disso para avaliar o poder da modelagem alguns parâmetros são analisados, como o Coeficiente de determinação do ajuste ( $R^2$ ), Raiz do Erro Quadrático Médio (*Root Mean Square Error* - RMSE), Viés e o *Variance Inflation Fator* (VIF), Equações 2.10, 2.11 e 2.12 2.13, respectivamente.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (2.11)$$

$$Viés = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (2.12)$$

$$VIF = \frac{1}{1 - R^2} \quad (2.13)$$

Onde:  $n$ : é o número de parcelas;  $y_i$  é o valor observado na parcela  $i$ ;  $\hat{y}_i$  é o valor estimado na parcela  $i$ ;  $\bar{y}$  é a média dos valores observados.

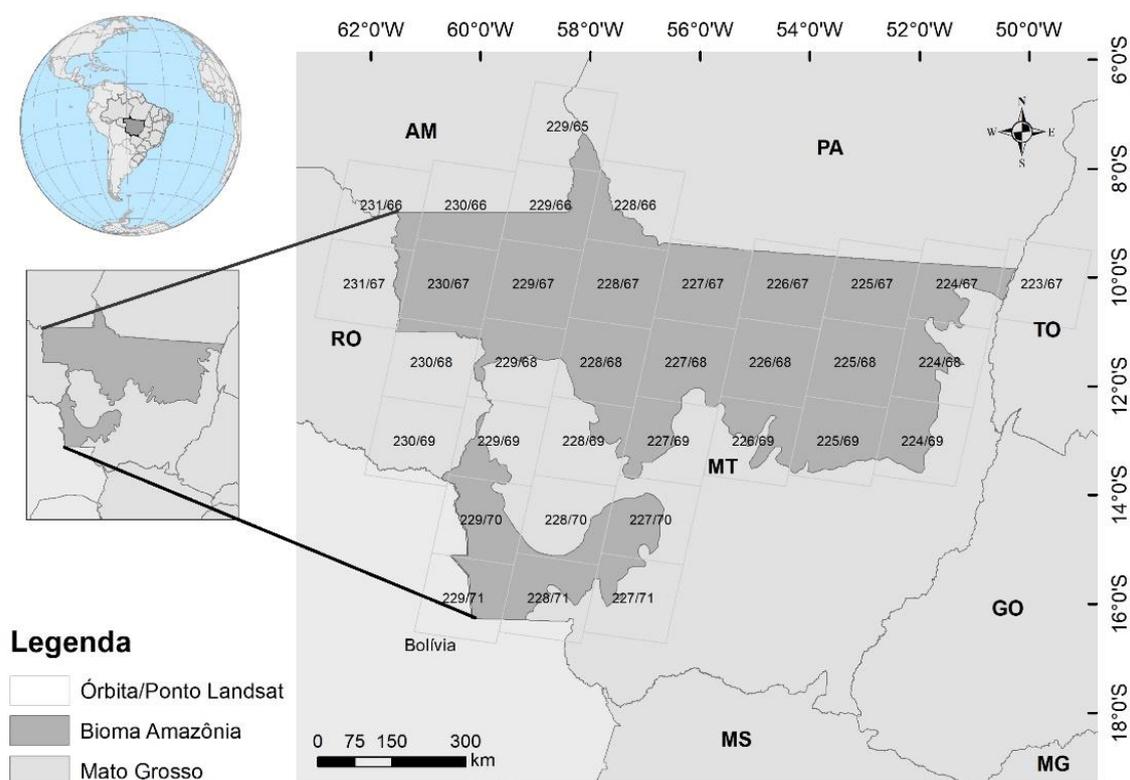
Durante a modelagem da biomassa e geração de modelos, uma etapa importante é a validação do modelo. A validação é capaz de testar a capacidade preditiva de um modelo ajustado (LOAGUE; GREEN, 1991), bem como o erro associado no processo de estimação da biomassa florestal. Dentre as técnicas de validação cruzada, a *Leave one out* (LOO) tem sido empregada para avaliar a predição de biomassa em florestas tropicais quando não se tem muitas parcelas (FERRAZ et al., 2016; SILVA et al., 2017).

### 3 MATERIAIS E MÉTODOS

#### 3.1 Área de estudo

A área de estudo (480.214,809 km<sup>2</sup>) compreende a região abrangida pelo bioma Amazônia no estado do Mato Grosso, Centro-Oeste brasileiro entre as coordenadas 7°00'S e 17°00'S de latitude e 50°00'O e 62°00'O de longitude (Figura 3.1). Por ser uma região de intensa exploração de madeira, o desmatamento e as queimadas são eventos constantes nesta região, tornando esta área um local importante para ser avaliado e estudado.

Figura 3.1 - Localização da área de estudo.



Destaque para a área em cinza escuro o qual representa os limites do bioma Amazônia no estado do Mato Grosso (IBGE, 2004).

Fonte: Produção do autor.

### 3.1.1 Clima

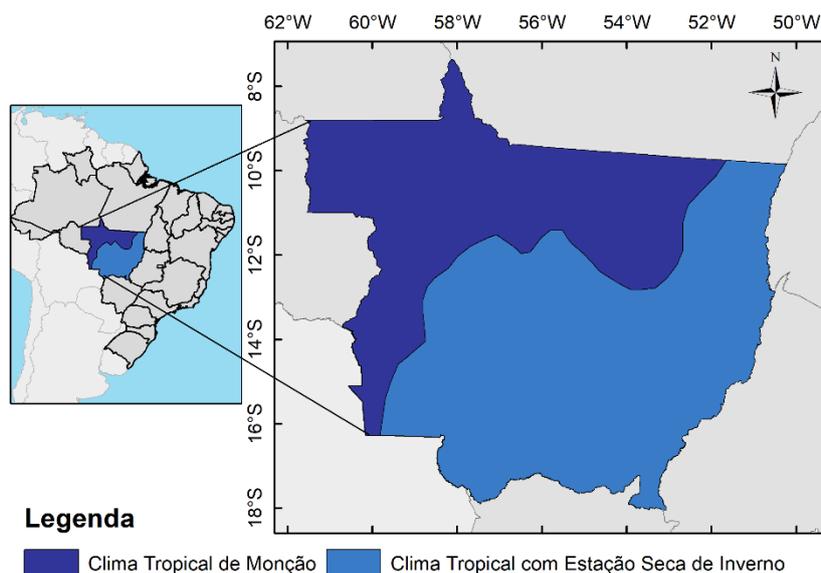
Alvares et al. (2014) elaboraram um mapa climático segundo os critérios de Köppen para o Brasil (Figura 3.2). Os autores apresentam que no estado do Mato Grosso há duas classificações climáticas, clima tropical com estação seca de inverno (Aw) e clima tropical de monção (Am). O clima Aw está distribuído, principalmente na porção centro sul do estado. Apresenta uma estação chuvosa no verão, de novembro a abril, e uma estação seca no inverno, de maio a outubro.

A temperatura média do mês mais frio é superior a 18°C e as precipitações são superiores a 750 mm anuais, atingindo 1800 mm (GOLFARI et al., 1978). Já o clima Am, abrange a região Norte e parte da região Nordeste do estado do Mato Grosso e é caracterizado com um clima tropical de monção, onde a precipitação anual é de cerca de 2.000 mm com inverno seco.

Segundo (NIMER, 1972) as características do regime de chuvas na Região Centro-Oeste estão relacionadas aos sistemas de circulação atmosférica, onde a pluviometria atinge valores mais elevados no Norte do Mato Grosso e reduz ao se deslocar para o Sul do estado, onde atinge níveis inferiores a 1250 mm. Ainda segundo o mesmo autor, para praticamente toda a região, mais de 70% do acumulado de chuvas no ano ocorre entre os meses de novembro a março e não apresenta uma distribuição igualitária no decorrer do ano. Entretanto, o período mais seco é durante a estação do inverno, onde as chuvas diminuem.

Mota et al. (2013) avaliaram o balanço hídrico climatológico no município de Sinop para o período de 1972 a 2010. Os autores encontraram que nos meses de outubro a março ocorreram 88,39% das precipitações anuais com média de 1.947 mm/ano para todo o período avaliado. Isto indica que a estação seca da região abrange os meses entre maio e setembro, em que ocorre uma diminuição ou inexistência de precipitação. O valor da temperatura média na região de Sinop é de 24,7°C, com pequena amplitude térmica anual, tendo médias mensais entre 23,5 e 25,5°C e máximas inferiores a 36°C.

Figura 3.2 - Classificação climática para o estado do Mato Grosso.

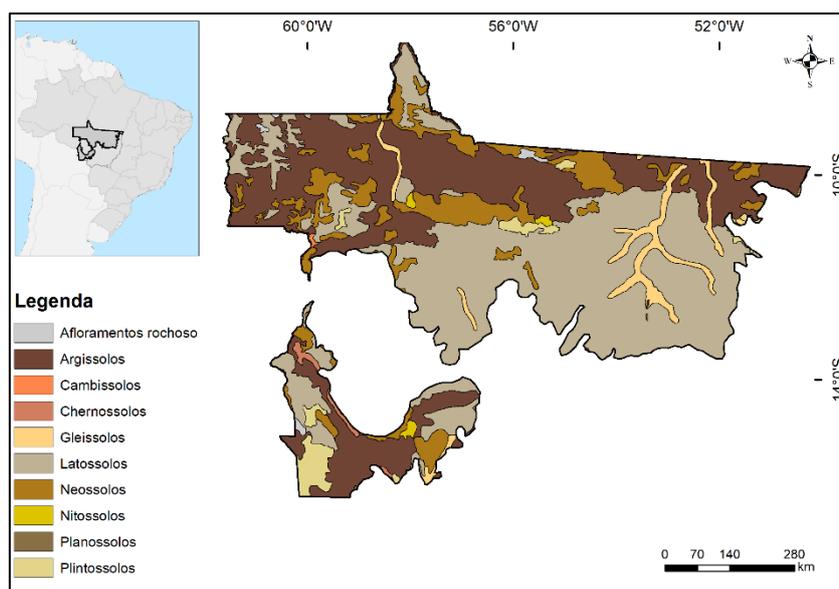


Fonte: Adaptado de Alvares et al. (2014).

### 3.1.2 Solos

A Figura 3.3 apresenta a distribuição dos solos na área de estudo. Destacam-se 6 tipos de solos, sendo os solos das seguintes ordens: Argissolo, Gleissolo, Latossolo, Neossolo, Nitossolo e Plintossolo.

Figura 3.3 - Mapa de solos para a área de estudo.



Fonte: Adaptada de EMBRAPA (2011).

Segundo o Sistema Brasileiro de Classificação de Solos (EMBRAPA, 2013), os Argissolos apresentam horizonte B textural imediatamente abaixo do A ou E, com argila de atividade baixa ou com argila de atividade alta conjugada com saturação por bases baixa e/ou caráter alítico na maior parte do horizonte B. Os Gleissolos são solos com horizonte glei iniciando-se dentro dos primeiros 150 cm da superfície do solo ou a profundidades entre 50 cm e 150 cm desde que imediatamente abaixo de horizonte A ou E.

Os Latossolos possuem horizonte B latossólico precedido de qualquer tipo de horizonte A dentro de 200 cm da superfície do solo. Neossolos são solos pouco evoluídos constituídos por material mineral ou por material orgânico com menos de 20 cm de espessura, não apresentando qualquer tipo de horizonte B diagnóstico. Já os Nitossolos são solos constituídos de material mineral, com 350 g.kg<sup>-1</sup> ou mais de argila, inclusive no horizonte A. O horizonte B apresenta argila de atividade baixa ou caráter alítico na maior parte do horizonte B dentro de 150 cm da superfície do solo. Por fim, os Plintossolos são solos constituídos por material mineral, apresentando horizonte plíntico (argila, pouco carbono orgânico, rica em ferro).

### **3.1.3 Vegetação**

No estado do Mato Grosso existem três biomas, Amazônia (53,6%), Cerrado (39,6%) e Pantanal (6,8%). No bioma Amazônia destaca-se, principalmente, a ocorrência de espécies vegetativas de dispersão pantropical, entre elas estão as famílias *Sapotaceae*, *Malvaceae* e *Fabaceae* (IBGE, 2012).

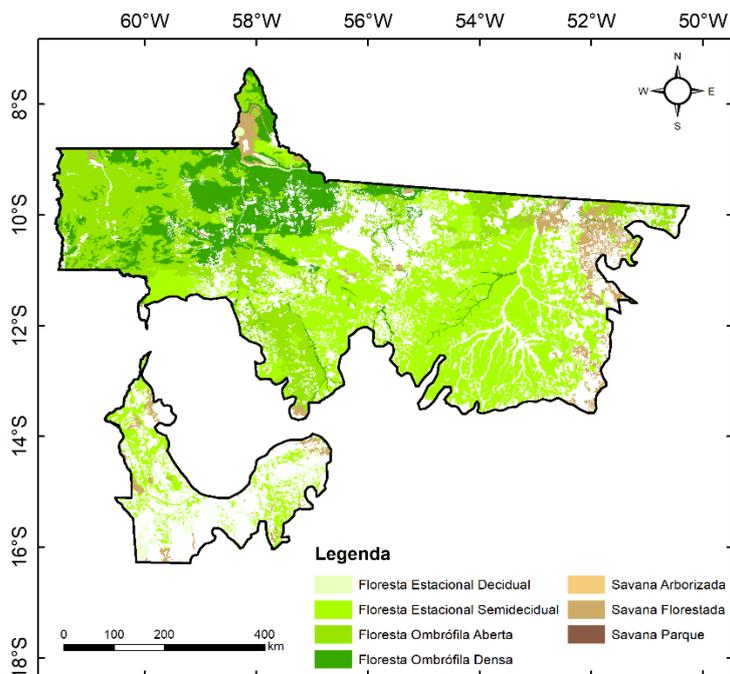
Na área de estudo, em sua grande parte, destaca-se a ocorrência das fitofisionomias, Floresta Estacional Semidecidual Submontana, Floresta Ombrófila Aberta Submontana, Floresta Ombrófila Densa Submontana além de algumas áreas de Savana. A Floresta Estacional Semidecidual Submontana ocorre ao sul do bioma amazônico no contato com a Savana (Cerrado). O clima estacional determina a semideciduidade das folhas da cobertura florestal. Na zona tropical está associada aos locais com acentuada seca e por intensas chuvas no verão. A formação Submontana situa-se na faixa altimétrica que

varia de 100 a 600 m de acordo com a latitude de 4° Norte até 16° Sul (IBGE, 2012).

Floresta Ombrófila Aberta Submontana pode ser observada distribuída por toda a Amazônia. O elevado potencial de água subterrânea, juntamente com os grandes rios contribui para o aumento da umidade, favorecendo um ambiente propício para a Floresta Ombrófila, como é o caso da região do Rio Juruena, Arinos e Sangue (IBGE, 2012).

Floresta Ombrófila Densa Submontana está associada a fatores climáticos tropicais de elevadas temperaturas (médias de 25°C) e precipitação bem distribuída durante o ano com até 60 dias secos. A vegetação de sub-bosque é composta por plântulas de regeneração natural com a ocorrência de palmeiras de pequeno porte e lianas. Caracterizada pela presença de indivíduos de alto porte, alguns ultrapassando 50 m na Amazônia e raramente 30 m nas outras partes do País. Esta formação é caracterizada por espécies que variam de acordo com a latitude (IBGE, 2012). A distribuição das fitofisionomias para a área de estudo pode ser observada na Figura 3.4.

Figura 3.4 - Fitofisionomias na área de estudo.

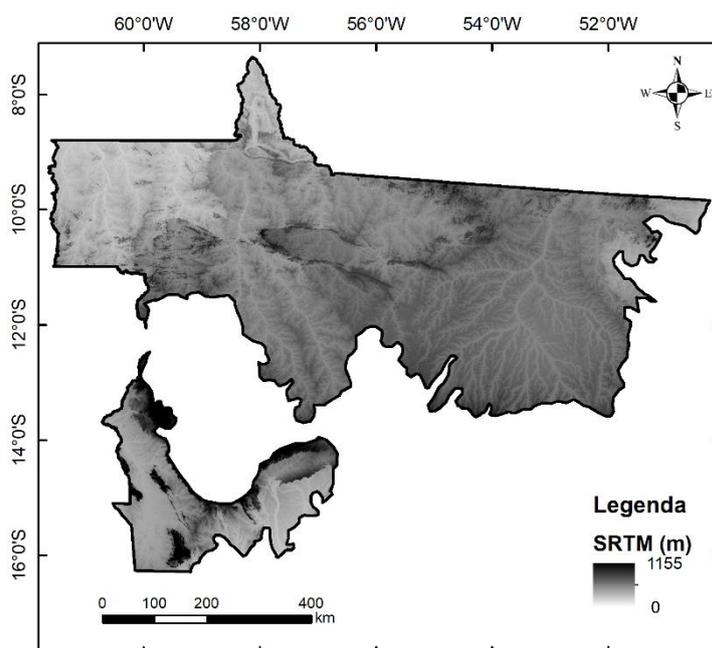


Fonte: Adaptada de IBGE (2012).

### 3.1.4 Relevo

O relevo nesta região está sobre o Maciço Mato-Grossense. Este exhibe complexas estruturas geológicas, sobre as quais vieram a se depositar sedimentos. Este maciço apresenta-se elevado ao sul, onde são encontradas suas maiores altitudes: 800-1200 metros. A norte apresenta altitudes médias de 200-500 metros. A Figura 3.5 apresenta o relevo a partir dos dados *Shuttle Radar Topography Mission* (SRTM) na porção amazônica no estado do Mato Grosso.

Figura 3.5 - Imagem SRTM do relevo na área de estudo.



Fonte: SRTM (FARR et al., 2007).

### 3.2 Materiais

Para a elaboração do presente estudo foram utilizados dados de campo, dados LiDAR e dados de imagens orbitais dos sensores a bordo dos satélites Landsat 5 e 8.

### **3.2.1 Dados de campo**

Os dados de campo utilizados no presente estudo são provenientes do projeto Paisagens Sustentáveis e de uma campanha de campo que foi realizada entre o final de julho e o começo de agosto de 2017. A seguir estes dados são descritos em detalhes.

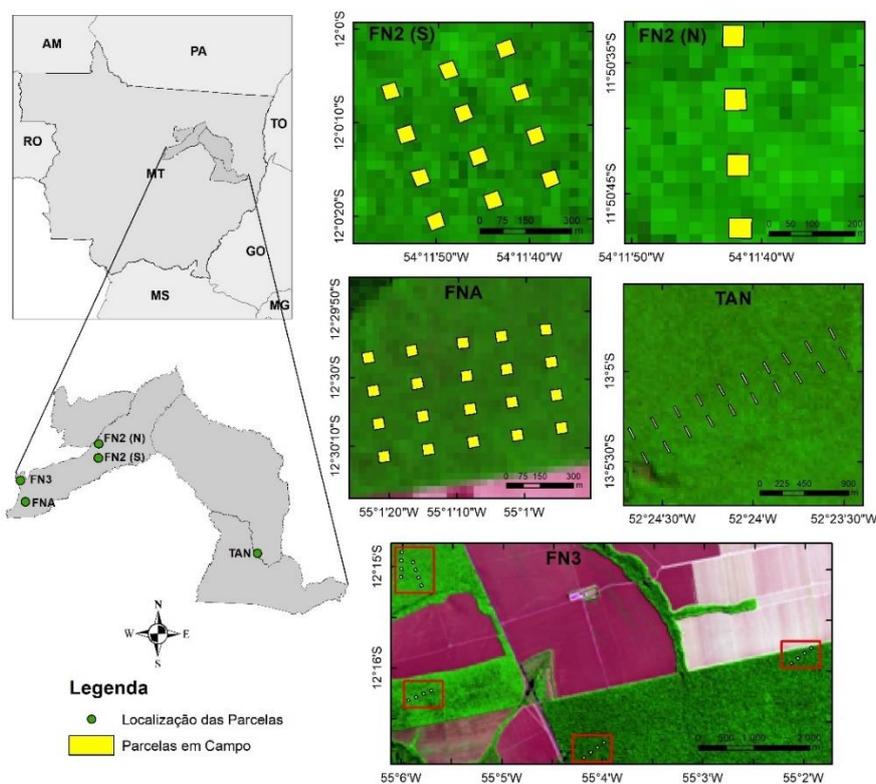
#### **3.2.1.1 Paisagens Sustentáveis**

Parte dos dados de campo, utilizados neste trabalho, foram adquiridos junto ao banco de dados do Projeto Paisagens Sustentáveis<sup>1</sup>, desenvolvido conjuntamente pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), *US Forest Service* (USFS) e *United States Agency for International Development* (USAID) com o objetivo de desenvolver novas metodologias e conhecimento, através de técnicas de contabilização de carbono no âmbito do REED+ (Redução das Emissões por Desmatamento e Degradação). A distribuição espacial dos sites do projeto (FNA, FN2, TAN e FN3) e das em cada site pode ser observada na Figura 3.6.

---

<sup>1</sup> <https://www.paisagenslidar.cnptia.embrapa.br/webgis/>

Figura 3.6 - Área de coleta dos dados de campo no Mato Grosso pelo Projeto Paisagens Sustentáveis.



Fonte: Produção do autor.

Foram utilizados um total de 76 parcelas inventariadas pelo projeto Paisagens Sustentáveis. As variáveis mensuradas foram DAP, altura total, altura comercial, identificação da espécie, raio de copa nas orientações norte, sul, leste e oeste, se a árvore estava viva ou morta, posição relativa da árvore em relação ao dossel (Emergente, Nível do dossel e Suprimida), coordenadas e índice de iluminação da copa (completamente iluminada, parte da copa recebe luz direta e a copa so recebe luz indireta). Dentre estas parcelas, dois sites mensurados foram afetados por fogo em mais de uma ocasião, enquanto que em três áreas houve degradação por meio de corte seletivo.

A área FNA foi afetada por fogo nos anos 2006, 2008 e 2011 e o inventário foi realizado em 2013. A metodologia usada para a coleta dos dados consistiu em 20 parcelas de 50 m x 50 m, nas quais todos os indivíduos com Diâmetro a Altura do Peito (DAP)  $\geq 5$  cm foram mensurados (PAISAGENS

SUSTENTÁVEIS, 2013). Devido ao fato de que grande parte dos indivíduos foram queimados, a coleta das variáveis dendrométricas para este local se procedeu em uma classe diamétrica menor do que nas demais áreas.

Nas áreas FN2, o inventário a campo foi realizado no ano de 2015 e, diferentemente da área FNA, elas não foram afetadas por fogo, mas foram submetidas ao corte seletivo em 2006 e 2007. Assim como na área FNA, foram delimitadas 16 parcelas com dimensões de 50 m x 50 m, sendo que 4 mais a norte (N) e 12 mais ao sul (S). Todos os indivíduos com DAP  $\geq$  30 cm foram mensurados. Também foram alocadas, no interior de 16 parcelas, subparcelas de 5 m x 50 m, onde todos os indivíduos com DAP  $\geq$  10 cm foram medidos (PAISAGENS SUSTENTÁVEIS, 2015). Esta metodologia foi a mesma empregada nas 20 parcelas da área FN3.

Para a área TAN as medições em campo ocorreram no ano de 2012, sendo distribuídas em 10 transectos de dimensões 20 m x 500 m, totalizando uma área amostral de 10 ha, onde todas as árvores com DAP  $\geq$  35 cm foram mensuradas. Nesses 10 transectos, também foram alocadas subparcelas de 2 m x 500m, onde todos os indivíduos com DAP  $\geq$  10 cm foram mensurados (PAISAGENS SUSTENTÁVEIS, 2012). Nesta área, cerca de 150 ha da floresta sofreu queimada múltiplas vezes para um estudo a longo prazo relacionado com fogo (BALCH et al., 2008; BRANDO et al., 2014). Cada transecto foi subdividido em 2 parcelas de 20 m x 125 m para apresentarem a mesma área que as outras parcelas (2500 m<sup>2</sup>). Foi considerado um espaço entre os transectos de 100 m para evitar autocorrelação espacial. Além disso, os diferentes DAP mensurados foram normalizados da seguinte maneira: A biomassa calculada a partir dos indivíduos mensurados nas subparcelas foi extrapolada para toda a parcela. Por fim esta biomassa calculada a partir das menores classes diamétricas foi extrapolada para o restante das parcelas.

### **3.2.1.2 Caracterização da campanha de campo**

Realizou-se uma campanha de campo entre os meses de julho e agosto de 2017, financiada pela Fundação de Amparo à Pesquisa do Estado de São

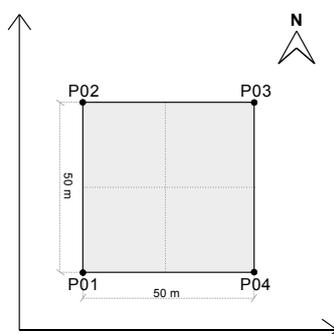
Paulo (FAPESP), mediante o projeto intitulado de “Mapeamento e monitoramento da degradação florestal utilizando dados de sensores remotos com resolução espacial média e moderada”.

Para a alocação das parcelas, previamente, buscou-se áreas que haviam sido sobrevoadas para a aquisição de dados LiDAR. Nestas áreas, ainda houve a tentativa de encontrar aquelas com presença de floresta intacta, ou seja, sem a incidência de fogo ou corte seletivo a partir da análise visual das imagens de satélite.

Com o auxílio de um Sistema de Informação Geográfica (SIG), a localização das parcelas foi definida nos locais onde haviam dados LiDAR do projeto EBA. Também avaliou o acesso até a parcela e proximidade com estradas. Esta localização foi exportada para um GPS de navegação e durante a campanha, o acesso até a localização da parcela foi guiado pelo aparelho de navegação.

A alocação da parcela (Figura 3.7) ocorreu primeiramente pelo vértice inicial, o qual foi comumente adotado como o ponto inferior esquerdo (P01). A partir deste, com o auxílio de uma bússola, a direção dos pontos cardeais foi localizada e media-se 50 m para Norte, o qual seria o vértice 2 (P02) e 50 m para Leste formando o vértice 4 (P04). A partir do P02 media-se 50 m para Leste para obter o ponto vértice 3 (P03). No final, caso a medida entre P03 e P04 não fosse de 50m, significava que a parcela não estava bem enquadrada. Então corrigia-se a posição dos vértices 3 e 4.

Figura 3.7 - Esquema demonstrando a alocação da parcela de campo.



Fonte: Produção do autor.

Em cada parcela coletou-se as seguintes informações dos indivíduos arbóreos com DAP  $\geq 30$  cm: circunferência a altura do peito (CAP), altura total (Htot), altura comercial (Hcom), raio da copa nas orientações norte (RN), sul (RS), leste (RL) e oeste (RO), nome científico da espécie, a posição relativa do dossel da copa (Emergente, Dominante ou Dominada), se a árvore estava Viva ou Morta, a localização das árvores com GPS de navegação, bem como a localização X e Y de cada árvore na parcela, além disso, os pontos dos quatro vértices das parcelas foram coletados com GPS de precisão e realizado a correção diferencial.

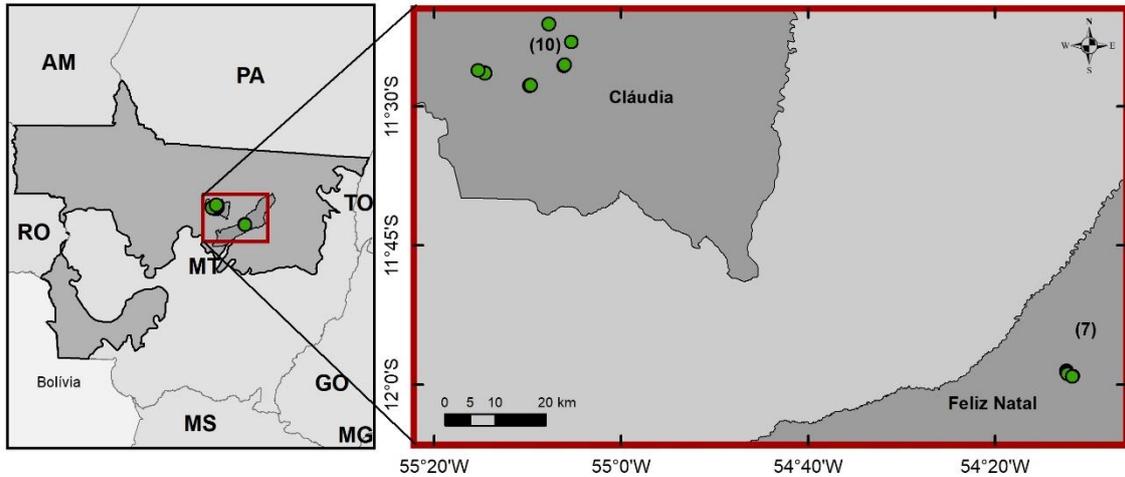
Todas estas medidas foram realizadas pela equipe de campo composta por: dois estudantes de mestrado, um de doutorado, além de um mateiro e um identificador botânico contratados previamente a partir da indicação do IBAMA de Alta Floresta e Sinop, MT.

Ao todo foram mensuradas 17 parcelas de 2500 m<sup>2</sup> com dimensão de 50 m x 50 m nos municípios de Claudia e Feliz Natal, no estado do Mato Grosso (Figura 3.8). Para facilitar o processo de mensuração das parcelas estas foram subdivididas em 4 quadrantes de 25 m x 25 m e mediu-se os indivíduos por quadrante.

A partir do vértice inferior esquerdo, convencionalmente adotado com as coordenadas de origem, ou seja (0, 0), se obteve o X e Y de cada árvore. O DAP foi obtido, a priori, com a mensuração da Circunferência a Altura do Peito (CAP) dos indivíduos a campo e este foi então dividido por pi ( $\pi$ ). A altura total (Htot), altura comercial (Hcom), raios de copa e posição relativa da copa foram mensuradas por meio de estimativa visual devido a experiência do identificador a campo.

Os dados mensurados a campo foram organizados em planilhas eletrônicas e para cada espécie identificada durante o inventário foi obtido a Densidade Básica da Madeira - DBM ( $\rho$ ) em g/cm<sup>3</sup> a partir do banco global organizado por Chave et al. (2009) e Zanne et al. (2009).

Figura 3.8 - Localização das parcelas de inventário coletadas na campanha de campo.



Cada círculo verde representa a parcela alocada, devido a sobreposição pela escala utilizada, o número de parcelas encontra-se entre parênteses.

Fonte: Produção do autor.

### 3.2.2 Dados LiDAR

Foram utilizados dados LiDAR disponibilizados pelo projeto Paisagens Sustentáveis, cujas aquisições ocorreram a partir de 2011. Foram sobrevoadas áreas em que ocorreram eventos de degradação florestal (queimada ou corte seletivo). Grande parte dos dados coletados encontra-se na região da Amazônia Legal, porém existem dados em outros estados brasileiros, como Goiás, São Paulo e Santa Catarina.

Além destes, também foram utilizados dados LiDAR do projeto Estimativa de Biomassa na Amazônia (EBA), que é desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE) e pela Fundação de Ciência, Aplicações e Tecnologia Espaciais (FUNCATE) apoiado pelo Fundo da Amazônia e pelo Banco Nacional do Desenvolvimento (BNDES). Este projeto está inserido no programa Monitoramento Ambiental por Satélite no Bioma Amazônia (MSA), o qual está dividido em sete áreas de trabalho, sendo que o EBA pertence a área 7: Melhoria dos Métodos de Estimativa de Biomassa e de Modelos de Estimativa de Emissões por Mudança de Uso da Terra.

### **3.2.2.1 Paisagens Sustentáveis**

Dentro do projeto Paisagens Sustentáveis os dados LiDAR disponíveis para o Mato Grosso possuem voos em diferentes locais e também em diferentes datas. Nos locais em que possuem mais de um voo (dados multitemporal), a seleção do voo ocorreu baseado na menor diferença temporal entre a imagem orbital livre de nuvens da área e a data da realização do voo.

As informações referentes à aquisição de cada um dos voos utilizados estão resumidas na Tabela 3.1, assim como a localização de cada voo está apresentada na Figura 3.9.

Vale ressaltar que, algumas áreas possuem mais de um voo LiDAR (site), como é o caso da FN3 que está dividida em 30 sites, FNC está dividida em 4 sites e FND em 2 sites. Neste caso somam-se 41 sites coordenados pelo projeto Paisagens Sustentáveis no estado do Mato Grosso, os quais foram utilizados neste trabalho.

Tabela 3.1 - Características da aquisição dos dados LiDAR nas áreas voadas pelo Projeto Paisagens Sustentáveis no estado do Mato Grosso.

	Área							
	COT	FN1	FN2	FN3	FNA	FNB	FNC	FND
<b>Sensor</b>	Optech ALTM 3100	Optech ALTM 3100	Optech ALTM 3100	Optech Orion M300	Optech, Orion M300	Optech Orion M300	Optech ALTM 3100	Optech ALTM 3100
<b>Data da aquisição</b>	Nov, 2011	Mar, 2016	Mar, 2016	Jun-Jul, 2017	Ago, 2013	Jun, 2015	Abr, 2017	Abr, 2017
<b>Densidade média de retorno (pts/m<sup>2</sup>)</b>	23,8	32,44	30,71	30,71	38,34	38,59	14,45	14,02
<b>Densidade média do primeiro retorno (pts/m<sup>2</sup>)</b>	14,39	23,28	23,71	16,28	25,84	29,82	-	-
<b>Frequência de amostragem (Hz)</b>	59,8	40,0	40,0	83,0	67,5	83,0	40	40
<b>Área sobrevoada (ha)</b>	1000	995	995	2998	1200	1007	1997	889,7
<b>Sobreposição entre faixas (%)</b>	65	70	70	65	65	65	70	70
<b>Altura de voo (m)</b>	850	850	850	850	853	850	850	850
<b>Campo de visada (°)</b>	11	15	15	12	9,8	12	15	15

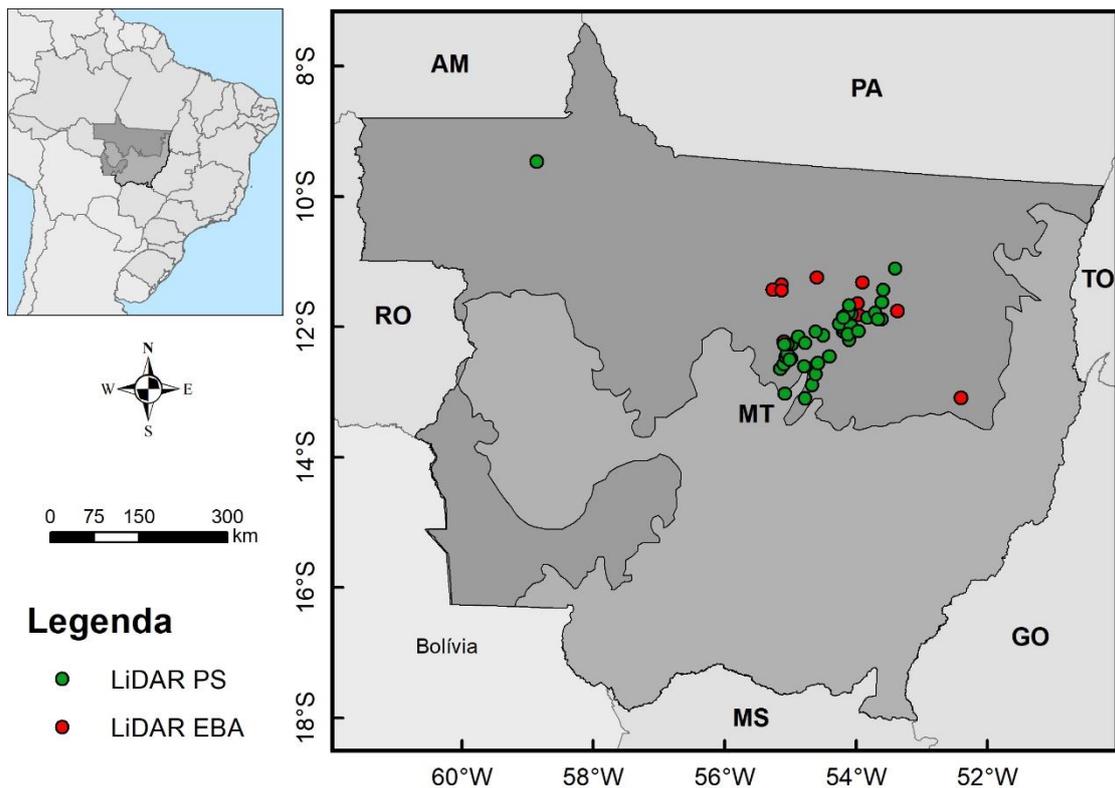
Fonte: Paisagem Sustentáveis, Metadados (2017).

### 3.2.2.2 Projeto Estimativa de Biomassa na Amazônia (EBA)

Foram utilizados 11 transectos provenientes do projeto EBA (T\_168, T\_175, T\_301, T\_302, T\_303, T\_304, T\_411, T\_412, T\_433, T\_607, T\_622). Estes voos estão inseridos nos limites do estado do Mato Grosso e contribuíram para aumentar a seleção amostral de dados LiDAR para a região.

Os dados provenientes do projeto EBA adotam a metodologia de transectos distribuídos aleatoriamente no bioma amazônico com as dimensões de 300 m x 12,5 km (375 ha). As características de voo estão resumidas na Tabela 3.2, bem como as datas de cada voo na Tabela 3.3. A Figura 3.9 apresenta a localização dos transectos utilizados no estudo obtidos do projeto EBA e Paisagens Sustentáveis.

Figura 3.9 - Localização dos voos LiDAR realizados no estado do Mato Grosso pelo projeto Paisagens Sustentáveis e pelo projeto EBA.



Fonte: Produção do autor.

Tabela 3.2 - Características resumidas da aquisição dos dados LiDAR do projeto EBA.

<b>Atributo</b>	<b>EBA</b>
Sensor	Trimble Harrier 68i
Data da Aquisição	2016
Densidade de pontos	≥ 4 pts/m
Frequência	5 - 200 Hz
Área sobrevoada	375 ha/transecto
Sobreposição entre faixas	0%
Altura de voo	600 m
Ângulo de varredura	45°

Fonte: EBA (2017).

### 3.2.3 Imagens orbitais ópticas

Utilizaram-se imagens multitemporais dos sensores *Thematic Mapper* (Landsat-5/TM), *Enhanced Thematic Mapper Plus* (Landsat-7/ETM+) e *Operational Land Imager* (Landsat-8/OLI) para auxiliar na escolha das datas sobrevoadas pelo LiDAR na ocorrência de voos multitemporais e para a modelagem de biomassa. As imagens também serviram de auxílio para obter informações a respeito de eventos naturais ou antrópicos, que alteraram as propriedades e características físico, químicas e biológicas daquelas áreas, principalmente aqueles derivados de degradação florestal como eventos de queimada e corte seletivo.

As imagens foram adquiridas no âmbito do *United States Geological Survey*<sup>2</sup> (USGS) já convertidas em reflectância de superfície (Produto: *Landsat Surface Reflectance*), os quais tornam possível a obtenção de informações biofísicas dos alvos estudados.

Foram adquiridas imagens com a menor diferença temporal possível entre a data de cada voo LiDAR e a passagem do satélite. Nesta etapa, priorizou-se o menor intervalo de tempo entre as duas aquisições de dados, para minimizar qualquer efeito ocasionado pela fenologia da vegetação e algum evento que

---

<sup>2</sup> <https://earthexplorer.usgs.gov/>

possa alterar as propriedades daquele ambiente (degradação florestal). Além da variável tempo considerada na escolha das imagens, também buscou-se imagens com menor quantidade de nuvem, numa tentativa de reduzir interferência atmosférica como quantidade de aerossóis, incidência de nuvens e sombras.

A Tabela 3.3 apresenta a data da aquisição das 16 imagens ópticas utilizadas e a relação com os voos LiDAR. Nota-se que para uma mesma data pode ser observado mais de um voo LiDAR, como mencionado anteriormente.

Tabela 3.3 - Data de aquisição dos dados LiDAR e das imagens Landsat.

Área (n° de voos)	Transecto	Data da Aquisição LiDAR	Data da Imagem (Órbita/Ponto)
<b>COT (1)</b>	A01	14-nov-2011	18-set-2011 (229/67)
<b>FN1 (1)</b>	A01	15-ago-2013	10-ago-2013 (225/68)
<b>FN2 (1)</b>	A01	30-mar-2016	21-mai-2016 (226/68)
<b>FN3 (7)</b>	P01, P02, P03, P04, P05, P06, P07	22, 23-jun-2015	29-jun-2015 (225/68)
<b>FN3 (12)</b>	P08, P09, P10, P11, P12, P13, P14, P15, P16, P17, P18, P19	01, 02, 03, 05, 06-jul-2015	22-jul-2015 (226/68)
<b>FN3 (11)</b>	P20, P21, P22, P23, P24, P25, P26, P27, P28, P29, P30	01, 02, 03, 05, 06-jul-2015	22-jul-2015 (226/69)
<b>FNA (1)</b>	A01	12, 13-ago-2013	17-ago-2013 (226/69)
<b>FNB (1)</b>	A01	22-jun-2015; 01-jul-2015	22-jul-2015 (226/68)
<b>FNC (4)</b>	A01, A02, A03, A04	12-abr-2017	08-mai-2017 (226/68)
<b>FND (2)</b>	A02, A03	12-abr-2017	08-mai-2017 (226/69)
<b>EBA (3)</b>	165, 301, 302	13-fev-2016	18-mar-2016 (226/68)
<b>EBA (1)</b>	303	13-fev-2016	28-abr-2016 (226/68)
<b>EBA (1)</b>	304	13-fev-2016	08-fev-2016 (226/68)
<b>EBA (1)</b>	411	13-fev-2016	03-abr-2016 (226/68)
<b>EBA (1)</b>	412	13-fev-2016	29-dez-2015 (226/68)
<b>EBA (1)</b>	178	19-fev-2016	17-fev-2016 (224/69)
<b>EBA (1)</b>	607	16-abr-2016	19-abr-2016 (226/68)
<b>EBA (1)</b>	433	21-abri-2016	19-abri-2016 (226/68)
<b>EBA (1)</b>	622	02-mai-2016	28-abr-2016 (225/68)

Fonte: Produção do autor.

### **3.3 Métodos**

#### **3.3.1 Caracterização florística e estrutural**

A curva de acumulação de espécies foi utilizada para avaliar se a amostragem foi suficiente. Neste caso, esta curva não se aplica para estudos que envolvem a quantificação de biomassa, somente para estudo fitossociológicos. Os descritores fitossociológicos, o índice de Shannon-Wiener, a Equabilidade de Pielou foram utilizados para caracterizar a floresta.

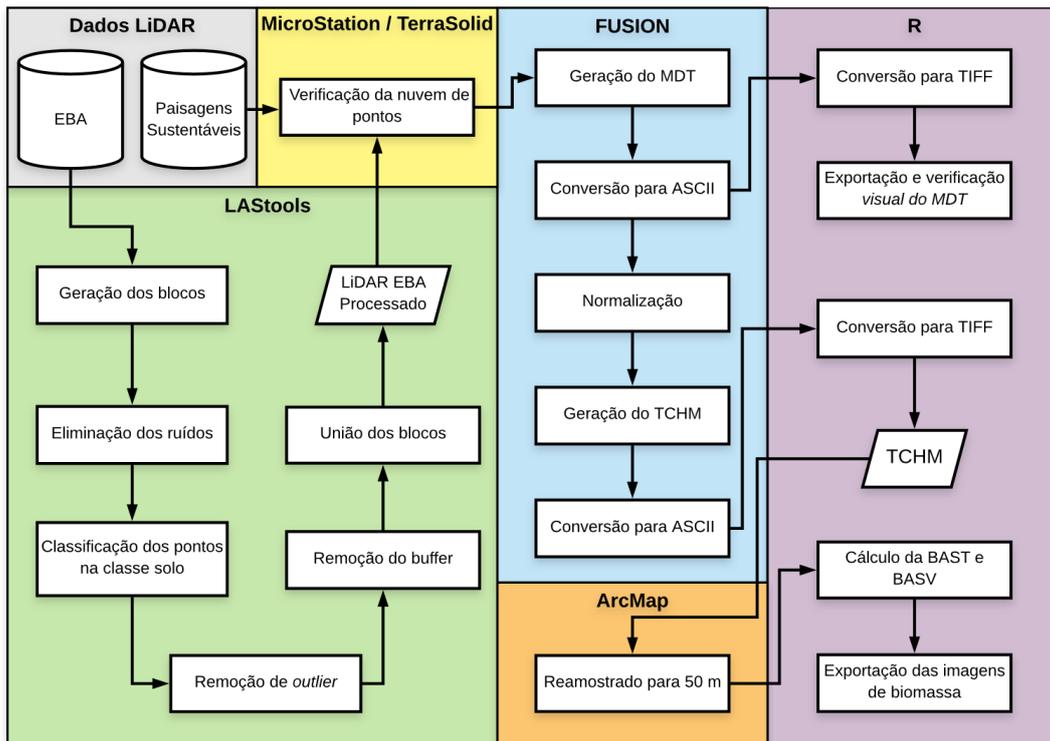
O Índice de dispersão de Morisita (MORISITA, 1959b;1962) foi empregado para saber qual o tipo de distribuição apresentado por cada espécie mensurada em campo. Para isso utilizou-se o pacote “*vegan*” (OKSANEN et al., 2017) implementado em ambiente R (R CORE TEAM, 2016).

Neste pacote aplicou-se a função chamada “*dispindmorisita*” a qual é especificamente para o cálculo do Índice de Morisita. O resultado da aplicação desta função é uma matriz com os seguintes parâmetros: O valor para cada espécie do Índice de Morisita (variando de 0 a n), os limites inferiores e superiores do índice para uma distribuição aleatória, e o Índice de Morisita normalizado (variando de -1 a 1). Se o valor do Índice de Morisita normalizado for maior que 0,5 a distribuição é agregada. Se o valor for menor que -0,5 a distribuição é regular e se o valor do índice estiver entre -0,5 e 0,5 a distribuição é aleatória.

#### **3.3.2 Processamento dos dados LiDAR**

O processamento dos dados LiDAR seguiu duas rotinas, uma aplicada aos dados provenientes do Paisagens Sustentáveis (PS) e outra aplicada aos dados proveniente do EBA. A diferença entre as rotinas se deu pelo fato que os dados provenientes do EBA estavam em uma versão menos refinada e por este motivo exigiram certas etapas de processamento que os dados do PS não exigiram. As etapas de trabalho podem ser observadas na Figura 3.10.

Figura 3.10 - Fluxograma do processamento dos dados LiDAR.



Em cinza os bancos de dados utilizados. Em verde estão as etapas de processamentos dos dados do EBA que foram realizadas no LAStools. Em amarelo a verificação dos dados LiDAR no MicroStation/TerraSolid. Em azul, os procedimentos realizados no aplicativo FUSION. Em laranja o procedimento realizado no ArcMap e em lilás os processos realizados no R.

Fonte: Produção do autor.

No processamento dos dados LiDAR proveniente do EBA, foram seguidas as seguintes etapas:

A primeira etapa foi a geração dos blocos de processamentos (*tiles*). Este procedimento recorta a nuvem de pontos em blocos menores, de dimensões pré-definidas, para permitir o processamento computacional. Vale ressaltar que, nesta etapa a nuvem de pontos não sofre nenhuma alteração apenas foi dividida em vários arquivos que exigem menos memória durante o processamento computacional. Em adição, utilizou-se um *buffer* de 50 m na geração das *tiles* para não ocorrer a omissão de pontos durante o recorte e ocasionar a perda de informação durante o processamento.

Na sequência, realizou-se a eliminação do ruído, esta etapa é importante, pois há grande chance de algum tipo de ruído ter sido gerado durante o voo para a aquisição dos dados.

Após esta etapa, os pontos foram classificados em pontos pertencentes ao solo (classe: *ground*). Nesta etapa, foram testados alguns parâmetros no algoritmo para melhor classificação dos pontos nesta classe. Para aferir a classificação dos pontos na classe *ground*, foi avaliado visualmente o Modelo Digital gerado a partir dos pontos desta classe.

Para gerar o Modelo Digital basta informar qual classe de pontos o aplicativo irá utilizar, neste caso foi informado a classe *ground*, possibilitando assim a geração do Modelo Digital de Terreno (MDT). Com o MDT gerado foi observado se havia a presença de buracos ou protuberâncias no modelo, caso houvesse a presença destes, voltava-se na nuvem de pontos, desclassificava os pontos da classe *ground* classificados anteriormente e reclassificava-os utilizando parâmetros diferentes. Esta avaliação foi realizada por meio da interpretação visual, de forma a obter o MDT suave, pouco rugoso e principalmente, livre de buracos ou protuberâncias como *spikes*.

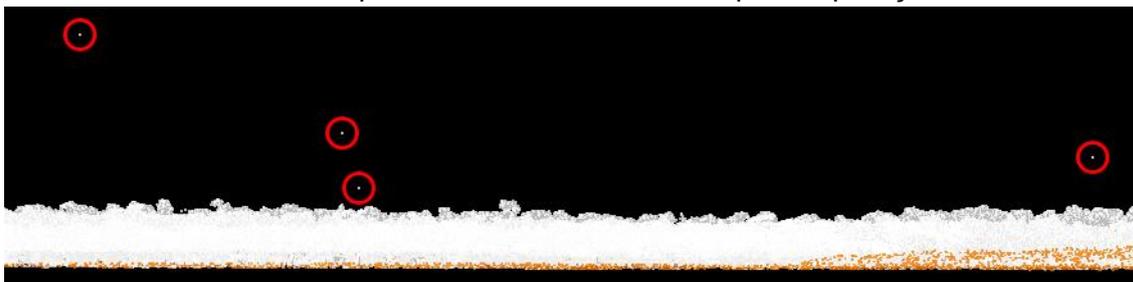
A nuvem foi filtrada para a remoção de pontos que estavam muito acima de nuvem ou muito abaixo, neste momento utilizou-se os parâmetros de 50 m e -2 m. Esta etapa utiliza os pontos classificados da classe *ground* e constrói um *Triangulated Irregular Network* (TIN) e depois calcula a altura de todos os outros pontos em relação a esta superfície. Todos os pontos que estão acima de 50 metros e abaixo de -2 metros em relação à TIN gerada são removidos. Por fim, removeu-se o *buffer* que havia sido gerado anteriormente e as tiles geradas foram unidas em um único arquivo.

A partir destas etapas, os procedimentos realizados nos dados do Paisagens Sustentáveis e EBA foram as mesmas, pois os dados LiDAR obtidos do Projeto Paisagens Sustentáveis já possuíam os pontos pertencentes a classe *ground* classificados.

Realizou-se a verificação visual no conjunto de dados LiDAR (PS e EBA) a partir da observação do perfil da nuvem. Com isso pode-se fazer a edição

manual dos pontos. No qual era observado se os ruídos haviam sido eliminados. Na maioria dos transectos, mesmo com a aplicação do filtro, ainda foi observado pontos muito acima da nuvem (Figura 3.11), estes foram então deletados. Este procedimento foi realizado em todos os 52 voos utilizados.

Figura 3.11 - Parte da nuvem de pontos perfilada e ruído dentro dos círculos vermelhos presente nos dados LiDAR após a aplicação do filtro.



Nos círculos vermelhos os ruídos na nuvem de pontos.

Fonte: Produção o autor.

As nuvens de pontos LiDAR foram processadas com o aplicativo FUSION 3.60 (MCGAUGHEY, 2016) auxiliado pelo programa R Studio (R CORE TEAM, 2016). Todas as ferramentas pertencentes ao aplicativo FUSION foram executadas a partir do R Studio para facilitar o processamento de múltiplos arquivos.

A primeira etapa se deu mediante a geração do Modelo Digital de Terreno (MDT), com 1 m de resolução espacial para cada voo, ou seja, 52 MDT's foram gerados nesta etapa de processamento, sendo que neste momento, cada voo foi processado individualmente. Durante o processamento foi necessário informar a qual fuso os dados LiDAR estavam contidos, como havia dados em diferentes fusos, preferiu-se processar os dados individualmente como uma medida de segurança.

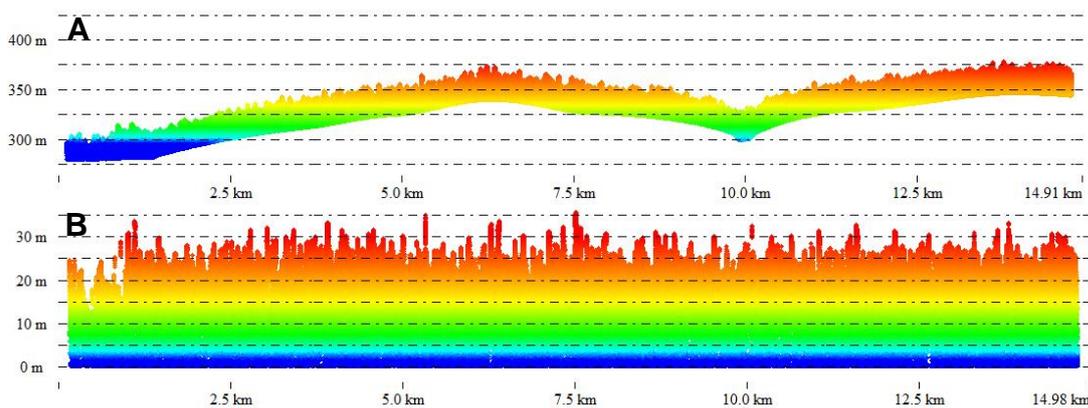
Por padrão, o MDT é gerado em formato .dtm o qual foi convertido para *American Standard Code for Information Interchange* (ASCII) e então para *Tagged Image File Format* (TIFF) e posteriormente exportado. Fez-se a avaliação visual do MDT gerado para cada voo, avaliou se os valores das

altitudes eram compatíveis com a altitude da região e se o modelo gerado não possui deformidades ou descontinuidades.

Com a geração dos MDT's a etapa seguinte foi efetuar a normalização dos dados. Este processo de normalização realiza a subtração dos valores de altitude de cada ponto em relação ao MDT gerado, com isso obtêm-se, para cada ponto, o valor de altura. A Figura 3.12 apresenta o exemplo do que acontece no processo de normalização da nuvem de pontos.

Com as nuvens de pontos normalizadas foi gerado o *Top Canopy Height Model* (TCHM) com resolução de 1 m para cada um dos transectos. Da mesma forma que os MDT's, os TCHM's também foram convertidos para ASCII e na sequência para TIFF e exportados.

Figura 3.12 - Perfil da nuvem de pontos.



Nuvem de pontos não normalizada em (A) e normalizada em (B).

Fonte: Produção o autor.

Os TCHM's gerados foram reamostrados para 50 m utilizando o método do Vizinho Mais Próximo, que minimiza as alterações nos valores dos *pixels*. Este procedimento foi realizado, pois o modelo preditor da biomassa a partir do TCHM foi calibrado com os dados em 50 m de resolução espacial (LONGO et al., 2016).

As Equações 3.10 e 3.11 desenvolvidas por Longo et al., (2016) foram utilizadas para calcular a biomassa acima do solo excluindo as árvores mortas em pé (BASV) e a Biomassa Acima do Solo Total (BAST) a partir dos dados LiDAR. Estas equações foram calibradas com dados do Projeto Paisagens

Sustentáveis, por este motivo utilizou esta equação na predição da biomassa oriunda dos dados LiDAR.

As equações foram desenvolvidas para estimar carbono em kg/m<sup>2</sup>, entretanto para calcular a biomassa basta multiplicar o resultado por 2 e por 10 para converter de kg/m<sup>2</sup> para Mg/ha.

$$BASV = (20) * 0,025 * TCHM^{1,99} \quad (3.10)$$

$$BAST = (20) * 0,054 * TCHM^{1,76} \quad (3.11)$$

Adaptado de Longo et al. (2016).

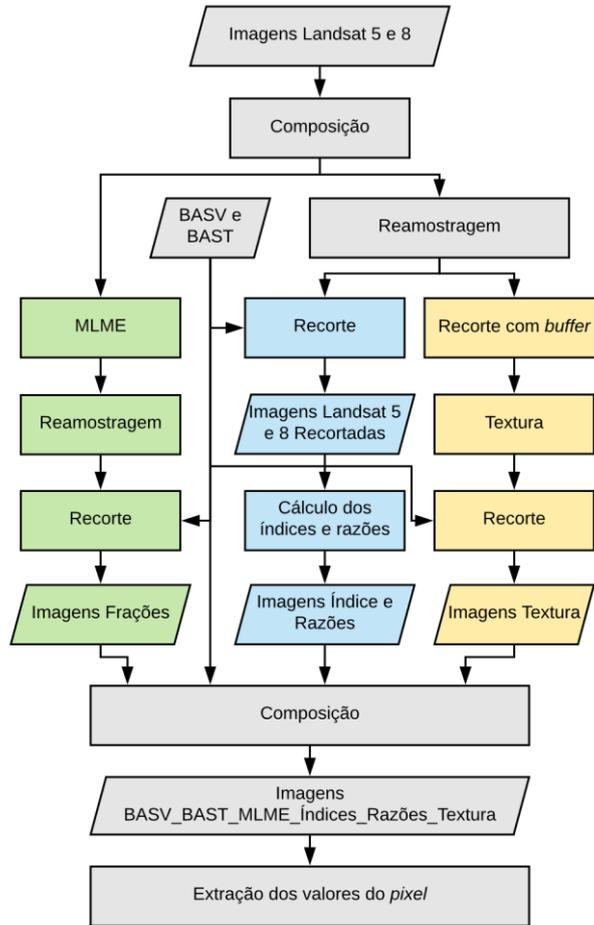
Onde: *BASV*: Biomassa Acima do Solo excluídas as árvores mortas em pé (Mg/ha). *TCHM*: *Top Canopy Height Model* (m). *BAST*: Biomassa Acima do Solo Total (Mg/ha).

Utilizou-se as equações que empregam apenas o TCHM como variável independente, pois em trabalhos anteriores os autores concluíram que o TCHM é menos impactado pela densidade de pontos da nuvem (HANSEN et al., 2015; OTA et al., 2015; GARCIA et al., 2017; SILVA et al., 2017). Os dados LiDAR utilizados possuem uma densidade de retorno de pontos variando de 4 a mais de 38 pts/m<sup>2</sup>.

### 3.3.3 Processamento das imagens ópticas

Após a aquisição das imagens, as bandas B2, B3, B4, B5, B6 e B7 do satélite Landsat-8/OLI foram agregadas em um único arquivo “*stack*”. Este procedimento também foi realizado para as bandas B1, B2, B3, B4, B5 e B7 do Landsat-5/TM, foram gerados dados de textura, índices de vegetação, razão entre bandas e imagens frações derivadas do Modelo Linear de Mistura Espectral. O fluxograma dos procedimentos realizados nas imagens orbitais pode ser observado na Figura 3.13.

Figura 3.13 - Fluxograma de processos realizados nas imagens orbitais.



Em verde, azul e laranja os procedimentos realizados para obtenção das imagens frações, índices/razões e textura, respectivamente.

Fonte: Produção do autor.

### 3.3.3.1 Modelo Linear de Mistura Espectral

Utilizou-se o *stack* de cada uma das 16 imagens e coletou-se os *endmembers* para rodar o Modelo Linear de Mistura Espectral (MLME). Os *endmembers* de vegetação, solo e sombra foram coletados individualmente para cada imagem, sendo obtidos no total de 16 *endmembers* de vegetação, solo e sombra. Para tornar as frações comparáveis entre elas, buscou-se o *endmember* máximo para cada componente dentre todos os *endmembers* coletados das imagens, e o modelo resultante foi aplicado em todas as cenas para o cálculo do MLME. Uma vez que ao utilizar o *endmember* máximo de um conjunto de imagens,

pode-se captar a maior parte da variação espectral daquela componente nas imagens.

As imagens frações foram reamostradas para 50 metros. Utilizou-se o método de Vizinho Mais Próximo para não ocorrer alteração tão significativa nos valores dos pixels das imagens frações. As frações reamostradas foram recortadas para a mesma área onde calculou-se a biomassa com os dados LiDAR.

Cada imagem fração, derivada das 16 cenas utilizadas foi recortada utilizando como máscara a imagem da biomassa gerada anteriormente para cada voo. Ou seja, como haviam 3 imagens fração e mais o erro para cada cena, o total foi de 64 imagens frações. Ainda no processo de recorte das imagens, é possível realizar o ajuste da localização dos *pixels*, de modo que o *pixel* da imagem recortada ficará na mesma localização da referência.

### **3.3.3.2 Índices de vegetação**

Ao todo testou-se 17 índices de vegetação disponíveis na literatura que serviram como possíveis dados de entrada para estimar a biomassa a partir de dados orbitais (Tabela 2.3), dentre eles: ARVI, DVI, EVI, GEMI, GARI, GNDVI, GVI, IPVI, MNLI, MSR, NLI, NDVI, OSAVI, RDVI, SAVI, TDVI, VARI.

Além das razões simples entre todas as bandas das imagens as quais somaram-se 15 razões de bandas entre as 6 bandas de cada imagem.

O procedimento dos índices e das razões entre bandas diferiram um pouco dos procedimentos adotados nas imagens frações. De modo que a primeira etapa foi reamostrar a composição com as 6 bandas para 50 m e na sequência o recorte das cenas para as áreas da biomassa, esta etapa ocorreu da mesma maneira que a realizada com as imagens frações. Na sequência, com o auxílio do aplicativo R, calculou-se os índices e as razões entre bandas para as áreas recortadas. Ainda no R, realizou a composição dos índices e das razões em uma única imagem de dimensão  $n=32$ . Foram geradas nesta etapa 52 imagens contendo a composição dos 17 índices mais as 15 razões.

### 3.3.3.3 Medidas de textura

Para complementar os índices de vegetação e as imagens frações durante a modelagem, calculou-se os dados de textura (GLCM) das imagens ópticas com janelas móveis de sete tamanhos distintos, 3x3, 5x5, 7x7, 9x9, 11x11, 13x13 e 15x15. Os *pixels* contidos nessas janelas foram utilizados para calcular oito medidas de textura: Média, variância, homogeneidade, contraste, dissimilaridade, entropia, segundo momento e correlação.

Os dados de textura por serem calculados a partir de uma janela móvel, realizou-se primeiramente um recorte para as áreas que houberam os voos LiDAR mas levando em consideração uma distância maior entre o limite do voo e a área a ser recortada.

As imagens composições, já reamostradas para 50 metros, foram recortadas com um buffer de 5 km, para garantir que a janela teria informações para calcular o valor da textura nas áreas que houve o voo.

Os dados de textura foram gerados para cada uma das bandas da composição, sendo calculado 8 medidas de textura para 7 janelas em 6 bandas. Isso foi realizado para todos os 52 recortes com o *buffer* de 5 km realizados anteriormente. No final deste processo cada uma das 52 áreas sobrevoadas possuía uma imagem de textura de dimensão  $n=336$ .

Como os recortes que haviam sido feitos anteriormente apresentavam o *buffer*, realizou-se novamente o recorte, mas desta vez utilizando a imagem da biomassa como máscara de acordo com o realizado para as imagens frações e índices.

Por fim, realizou a composição entre a BASV, BAST, imagens frações, índices de vegetação, razões, textura, para cada uma das 52 áreas. A partir disto, o valor do *pixel* de cada uma das 52 imagens geradas foi extraído e foi montada uma planilha eletrônica contendo o valor de todos os *pixels* em todas as dimensões.

### 3.3.4 Modelagem da biomassa florestal a partir dos dados orbitais

Foi realizado a modelagem tanto para a BASV, quanto para a BAST. As etapas de processamento realizadas para ambas as biomassas foram os mesmos, apenas foram alteradas a variável resposta das análises. Testou-se dois métodos para elaborar os modelos de biomassa, o primeiro a partir da pré-seleção das variáveis independentes com maior correlação de Pearson entre a biomassa e outro método sem a realização da pré-seleção.

Com o auxílio do aplicativo R foi calculado a correlação de Pearson entre a biomassa e os dados calculados anteriormente (imagens fração, índices/razões e textura). Na sequência, as variáveis com maior correlação com a biomassa foram selecionadas e gerou-se um subconjunto. Para isso foi selecionado as variáveis que apresentaram correlação maior que 0,3 e menor que -0,3.

Em paralelo, todas as variáveis (sem a pré-seleção) foram utilizadas para serem candidatas a comporem os modelos preditores da biomassa. Esta função baseia-se na seleção do melhor conjunto de variáveis a partir de uma busca exaustiva (MILLER, 1984; HUDAK et al., 2006).

A partir dos modelos de biomassa ajustados para os dados orbitais por meio dos dois métodos realizou-se a seleção do melhor modelo, para isso considerou-se o  $R^2$ , o RMSE, o Viés e o VIF dos modelos. Na sequência, procedeu-se a validação cruzada pela técnica *Leave One Out*. Por fim, o modelo foi utilizado para extrapolar a biomassa para a região compreendida pelo bioma Amazônia no estado do Mato Grosso.

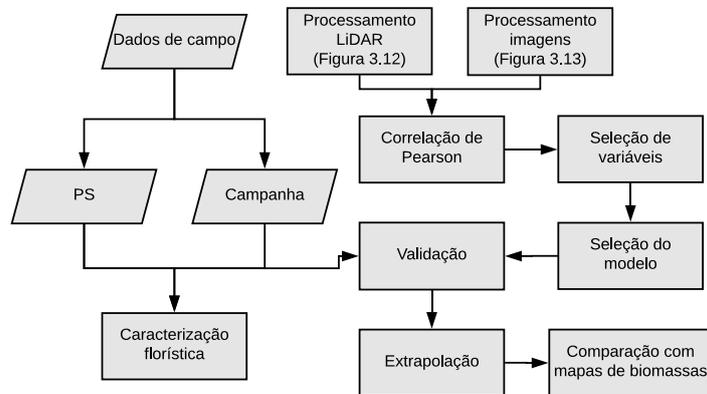
Para eliminar as áreas de agricultura utilizou-se uma máscara de floresta, a qual foi baseada nos dados de Hansen et al., (2013). Para a máscara referente ao ano 2000, utilizou-se o dado *TreeCover* e segundo a definição de floresta da FAO, (2012) definiu-se floresta onde o dossel apresentava mais de 10% de cobertura. Para o ano 2017 somou-se o Ganho e subtraiu-se a Perda do *TreeCover* até o último ano disponível (2016), e onde havia mais que 10% de cobertura florestal, definiu-se como florestal.

### 3.3.5 Comparação com os mapas de biomassa já existentes

Os mapas de biomassa utilizados para esta comparação foram os elaborados por Saatchi et al. (2011) e Baccini et al. (2017). Para poder realizar a comparação direta entre estes mapas de biomassa, utilizou-se a biomassa estimada a partir da exclusão dos indivíduos mortos em pé (BASV). Avaliou-se a diferença entre os valores da BASV e os mapas mencionados anteriormente.

A Figura 3.14 apresenta o fluxograma das etapas de processamento para a execução deste trabalho.

Figura 3.14 - Fluxograma da metodologia de trabalho.



Fonte: Produção do autor.

## 4 RESULTADOS E DISCUSSÃO

### 4.1 Caracterização florístico-estrutural

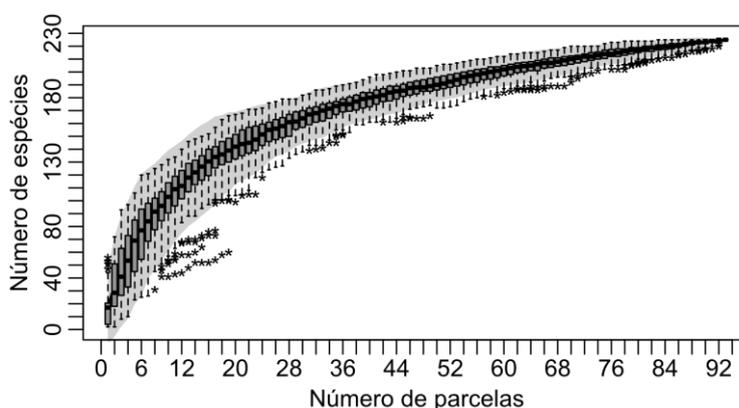
Ao todo foram utilizados dados de 93 parcelas, sendo 17 provenientes da campanha e 76 provenientes dos dados do PS. A mensuração nestas parcelas cobriu uma área de 23,25 ha, contendo 4.264 indivíduos em 225 espécies identificadas, distribuídas em 54 famílias botânicas. Deste total, há uma espécie e uma família identificadas como “Morta Não Ident.”, representando os indivíduos mortos que não foram possíveis identificar.

A Figura 4.1 apresenta a curva de acumulação de espécies por parcela amostrada. É possível observar uma redução no surgimento de novas espécies após 70 parcelas, o que representa uma área de aproximadamente 17,5 ha. Nota-se que a estabilização da curva não ocorreu mesmo com o surgimento de poucas espécies no final do intervalo (Figura 4.1), o que sugere que mesmo com grandes intensidades amostrais, o surgimento de espécies raras ainda pode ocorrer. Além de que o aumento na diversidade não necessariamente indica aumento de biomassa (FERREIRA et al., 2018).

De acordo com Kersten; Galvão (2011), a suficiência é satisfatória quando um aumento de 10% na área amostral resulta em um aumento inferior a 5% no número de espécies. Com a inclusão da 92<sup>a</sup> e 93<sup>a</sup> parcelas, que corresponde a pouco mais de 2% da área amostral, poderia ocorrer um aumento de até 1% nas espécies. O aumento observado foi de 2 espécies em 225 (0,89%), com isso considerou-se a amostragem suficiente para a caracterização da área de estudo.

Os indivíduos mensurados nas parcelas de campo foram, em sua maioria, distribuídos nas menores classes diamétricas, seguindo o comportamento de um “J invertido”, com a ocorrência de mais indivíduos nas menores classes diamétricas do que nas maiores. Conforme a dimensão dos indivíduos aumenta, a frequência de ocorrência destes diminuem, assemelhando-se a uma exponencial negativa (Figura 4.2). A presença de mais indivíduos pequenos e menos indivíduos grandes é algo normal para uma floresta natural (SOUZA et al., 2005).

Figura 4.1 - Curva de acumulação de espécies em relação ao número de parcelas amostradas.



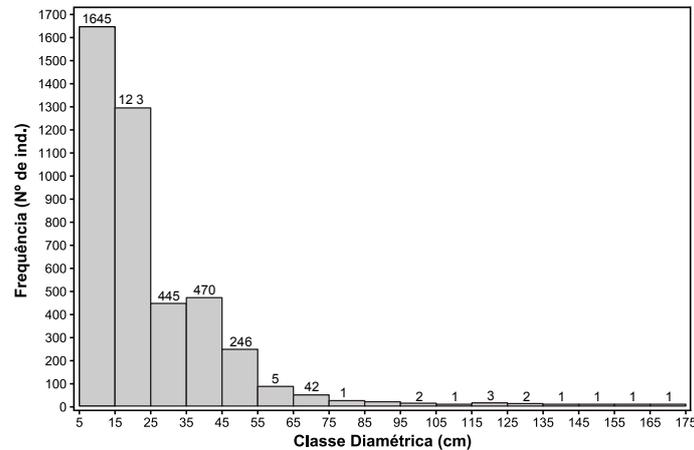
A área sombreada no gráfico indica a região ocupada pelas curvas geradas por 1000 permutações aleatórias das unidades amostrais. A variação do número de espécies em função da intensidade amostral é demonstrada por gráficos do tipo *boxplot*.

Fonte: Produção do autor.

Os parâmetros fitossociológicos, DA, DR, DO, DOR, FA, FR e VI foram obtidos para todas as espécies e estão apresentados na tabela no apêndice (Tabela D.1). Os valores para as dez espécies com maior Valor de Importância são apresentados na Tabela 4.1. Juntas elas somam 34,12% do VI total desta comunidade, correspondendo a 39,52% do número de indivíduos amostrados. O tipo de distribuição de cada espécie calculado a partir do Índice de Morisita está apresentado na tabela no apêndice (Tabela D.2).

O Índice de Shannon-Wiener ( $H'$ ) foi de 4,31 indicando um alto grau de incerteza em prever qual espécie pertenceria um determinado indivíduo sorteado aleatoriamente na comunidade, sendo um indicador de alta diversidade de espécies na área de estudo. A Equabilidade de Pielou ( $J$ ) foi de 0,80, quanto maior o valor da Equabilidade, menor será a dominância ecológica. Resultados semelhantes foram encontrados por outros autores na região de Sinop (ARAUJO et al., 2009) e na região de Querência (KUNZ et al., 2008).

Figura 4.2 - Distribuição dos indivíduos por classes de diâmetro.



Fonte: Produção do autor.

Tabela 4.1 - Descritores fitossociológicos para as dez espécies com maior Valor de Importância (em ordem decrescente).

Espécie	N	DA	DR	DoA	DoR	FA	FR	VI
<i>Morta Não Ident.</i>	491	17,38	11,52	1,38	15,11	86,73	5,93	10,85
<i>Protium sagotianum</i>	434	15,36	10,18	0,3	3,25	15,04	1,03	4,82
<i>Qualea paraensis</i>	155	5,49	3,64	0,63	6,88	28,32	1,94	4,15
<i>Protium heptaphyllum</i>	114	4,04	2,67	0,56	6,11	30,09	2,06	3,61
<i>Endlicheria ruforamula</i>	76	2,69	1,78	0,18	1,98	30,09	2,06	1,94
<i>Ocotea matogrossensis</i>	123	4,35	2,89	0,16	1,71	14,16	0,97	1,86
<i>Manilkara huberi</i>	49	1,73	1,15	0,23	2,56	23,89	1,63	1,78
<i>Jacaranda copaia</i>	85	3,01	1,99	0,11	1,21	29,2	2	1,73
<i>Trattinnickia rhoifolia</i>	91	3,22	2,14	0,2	2,14	13,27	0,91	1,73
<i>Sacoglottis guianensis</i>	67	2,37	1,57	0,15	1,61	25,66	1,75	1,65

Fonte: Produção do autor.

Parte das parcelas de campo haviam sido afetadas por fogo, principalmente naquelas adquiridas do projeto PS. Como resultado, o número de árvores mortas foi o mais representativo dentre todas as espécies. Cerca de 491 indivíduos foram identificados como mortos, o que equivale a 11,5% de todos os indivíduos amostrados. Este resultado evidencia a atuação das queimadas na morte dos indivíduos arbóreos, já apontado em estudos anteriores (ARAGÃO et al., 2007; VASCONCELOS et al., 2013). Além disto, as queimadas são apontadas no processo de intensificar a mortalidade de árvores em anos mais secos, onde a incidência de fogo é maior devido à escassez de

água (BRANDO et al., 2014). Isso contribui diretamente para o aumento da mortalidade devido ao fogo (BALCH et al., 2011) e, conseqüentemente, redução da biomassa (BRANDO et al., 2016; DEVISSCHER et al., 2016). Estudos recentes apontam que mesmo após 10 anos da ocorrência de fogo, os efeitos na estrutura florestal ainda podem ser observados, identificados principalmente pela redução da biomassa nestas áreas (SATO et al., 2016).

O corte seletivo, neste contexto, reduz o número de indivíduos nas maiores classes diamétricas, pois são árvores visadas pelos madeireiros dado seu valor econômico. Além de reduzir o número de indivíduos nas maiores classes diamétricas, a retirada das árvores abre clareiras no interior da floresta, favorecendo a entrada de luz e proporcionando a regeneração de espécies pioneiras e heliófilas (PINARD et al., 1996; LONGO et al., 2016).

Além disso, tanto em áreas de corte seletivo como em áreas de manejo florestal, a derrubada e arraste das árvores através dos ramais de escoamento da madeira e estradas ocasionam a mortalidade dos indivíduos (PEREIRA et al., 2002), reduzindo a biomassa e em áreas de manejo florestal sustentável também há degradação (ASNER et al., 2005).

#### **4.2 Estimativa de biomassa a partir dos dados LiDAR**

As Figuras 4.3a e 4.3b apresentam, respectivamente, o cálculo da Biomassa Acima do Solo Total (BAST) e da Biomassa Acima do Solo Viva (BASV) a partir dos dados LiDAR para as áreas sobrevoadas pelo projeto PS e pelo EBA. É possível observar valores menores de biomassa quando comparados com áreas de floresta intacta em outras áreas da Amazônia (CUMMINGS et al., 2002; SAATCHI et al., 2007).

Os valores baixos de biomassa encontrados são, em sua maioria, devido aos eventos de degradação florestal na região, como queimadas e corte seletivo, que causam a mortalidade e a remoção de grandes indivíduos, reduzindo diretamente os valores da biomassa florestal.

Em adição, as Figura 4.3c e 4.3d apresentam a biomassa calculada para cada área sobrevoada. Nas áreas que apresentavam mais de um voo, como o caso

da FN3, FNC e FND, os voos foram agregados para formar apenas um *boxplot*. A média da BAST foi de  $161,50 \pm 100,90$  Mg/ha e da BASV foi de  $150,05 \pm 101,100$  Mg/ha. A pequena diferença entre a biomassa total e viva se dá devido ao fato da biomassa viva desconsiderar as árvores mortas consideradas na biomassa total.

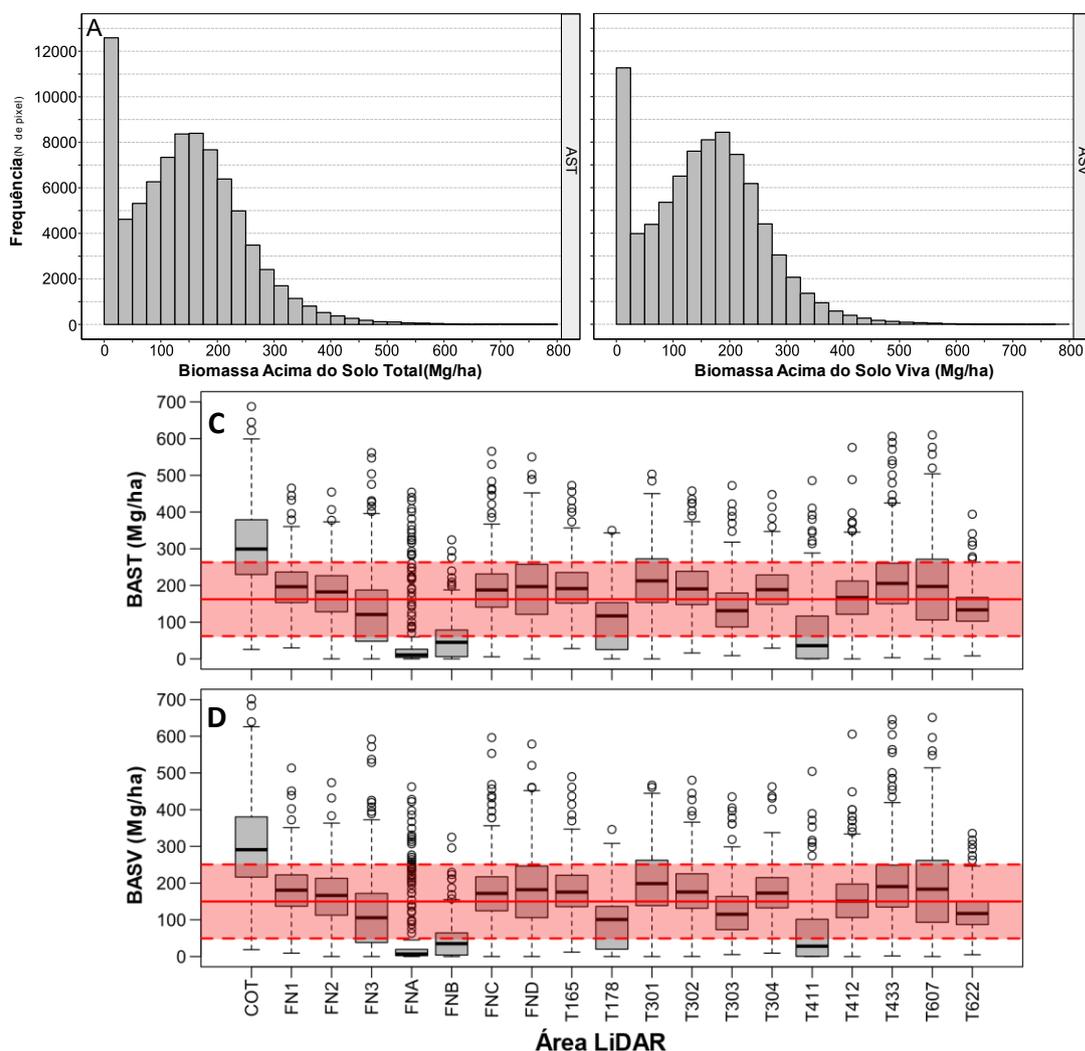
Na área FNA o voo LiDAR ocorreu em 2013 e os baixos valores de biomassa são resultado das queimadas que ocorreram sucessivamente em 2006, 2008 e 2011, identificados a partir da análise visual da série temporal. Os dados de campo nesta área, realizados pelo PS, foi conduzido em 2013 e retrata as características de uma área com alta mortalidade, com média de 56 indivíduos/ha nos 5 ha mensurados. Além disso, há um local com Área de Preservação Permanente (APP) que não foi afetada por fogo contribuindo para uma maior biomassa e neste caso a presença de tantos *outliers*.

A área COT, por estar localizada mais a Noroeste do estado do Mato Grosso, com menor contato com o Cerrado, apresentou maiores valores de biomassa dentre todas as áreas. As diferenças nas propriedades edafoclimáticas contribuem para haver uma maior biomassa naquela área (QUESADA et al., 2012). Uma destas propriedades é o volume pluviométrico, no qual tende a ser mais elevado no Norte do Estado do Mato Grosso (NIMER, 1972).

No estado do Mato Grosso devido a exploração madeireira e a legislação, a qual permite o manejo florestal, as áreas florestais, em sua grande maioria, em algum momento já foram afetadas por eventos de degradação, fazendo com que a biomassa seja menor. Em outros locais na Amazônia com a presença de floresta tropical de terra úmida, como aquelas encontradas na região de Manaus por exemplo, apresentam uma maior biomassa florestal, com cerca de  $343,05$  Mg/ha (HIGUCHI et al., 2005).

A biomassa calculada a partir de dados LiDAR no estado do Mato Grosso para estimar as emissões de gases de efeito estufa, devido às mudanças de uso da terra pelo desmatamento apresentaram uma média de  $269,3$  Mg/ha (FEARNSIDE et al., 2009).

Figura 4.3 - Distribuição da biomassa nas áreas sobrevoadas para aquisição dos dados.



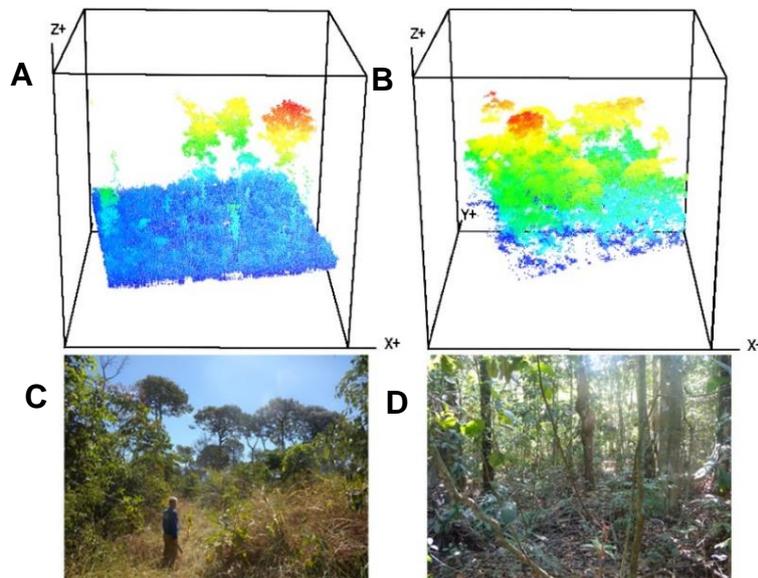
Em (A) o histograma da BAST; Em (B) o histograma da BASV; Em (C) e (D) a distribuição da biomassa total e viva, respectivamente para as áreas sobrevoadas para aquisição de dados LiDAR. Os 30 voos da área FN3 estão agregados, assim como os 4 voos da FNC e os 2 voos da FND. Na área em vermelho está a média (linha contínua) do valor da biomassa nas áreas e  $\pm$  o desvio padrão (linhas pontilhadas).

Fonte: Produção do autor.

A Figura 4.4 apresenta os diagramas baseados num recorte da nuvem de pontos LiDAR para uma parcela afetada por fogo (Figura 4.4a e Figura 4.4c) e em uma parcela afetada por corte seletivo (Figura 4.4b e Figura 4.4d). É possível, a partir da visualização tridimensional, observar os efeitos que estes

distúrbios causam na estrutura florestal, impactando diretamente na biomassa destas florestas afetadas pela degradação.

Figura 4.4 - Exemplo de parcela degradada por fogo e por corte seletivo juntamente com o recorte da nuvem de pontos LiDAR.



Em (A) e (C) a nuvem de pontos LiDAR e uma fotografia para uma parcela degradada por fogo. Em (B) e (D) a nuvem de pontos LiDAR e a fotografia da parcela degradada por corte seletivo.

Fonte: Produção do autor.

### 4.3 Análises de correlação entre as métricas derivadas das imagens Landsat e a biomassa estimada com os dados LiDAR

A análise da Correlação de Pearson entre todas as variáveis (índices de vegetação/razões, textura das bandas nas diferentes janelas e modelo linear de mistura espectral) variou entre -0,44 e 0,51 para a biomassa total e entre -0,41 e 0,48 para a biomassa viva. As maiores correlações tanto para BAST quanto para a BASV foram com as razões simples entre bandas, seguidas da textura média nas maiores janelas moveis para a banda do *Swir2*, vermelho.

A Tabela 4.2 e Tabela 4.3 apresentam os valores da correlação das variáveis Landsat com a biomassa total e viva (estimadas a partir do LiDAR), respectivamente. Todos os valores foram significativamente diferentes de 0 ( $p < 0,05$ ). Para entendimento das tabelas, a variável MSR é o índice de

vegetação, R\_N refere-se a razão entre a banda *Red* e *Nir*. A variável S2\_cor\_w7 refere-se a banda referente ao *Swir 2*, textura correlação na janela 7x7, sol a fração solo e assim por diante.

Eckert, (2012) avaliou a correlação de Pearson entre a biomassa florestal em área degradada e não degradada no Nordeste de Madagascar comparando índices de vegetação e alguns dados de textura a partir dos dados do Word-View-2. O autor obteve as correlações mais altas para os dados de textura nas maiores janelas móveis (15 e 23), cerca da 0,75. E em relação aos índices de vegetação a maior correlação foi com o EVI, 0,51. Ainda neste estudo, os dados que mais se correlacionaram com a biomassa foram a média e a correlação para todas as bandas da imagem. A resolução espacial do Word-View-2 (1,84 m multiespectral e 0,50 m pancromática), permite um maior detalhamento da floresta favorecendo a coleta das pequenas variações no dossel.

Tabela 4.2 - Correlação de Pearson entre as variáveis Landsat e a biomassa total.

Variável	Cor.	Variável	Cor.	Variável	Cor.	Variável	Cor.
MSR	0,30	S1_cor_w13	-0,32	S2_cor_w15	-0,35	S2_mea_w5	-0,35
R_N	-0,30	B_cor_w13	-0,32	S2_mea_w15	-0,35	S2_mea_w3	-0,35
S2_cor_w7	-0,30	B_cor_w15	-0,33	S1_mea_w13	-0,35	S1_mea_w7	-0,35
S2_dis_w9	-0,31	G_cor_w7	-0,33	S2_mea_w13	-0,35	S1_mea_w5	-0,36
R_cor_w9	-0,31	S1_var_w15	-0,33	R_mea_w13	-0,35	S2_ent_w15	-0,36
N_cor_w11	-0,31	S1_cor_w15	-0,33	R_mea_w15	-0,35	S1_mea_w3	-0,36
S1_cor_w11	-0,31	S1_var_w13	-0,33	R_mea_w11	-0,35	G_cor_w11	-0,36
G_R	0,31	S1_var_w11	-0,33	R_mea_w9	-0,35	VARI	0,37
S2_dis_w11	-0,31	S1_var_w9	-0,33	S2_mea_w11	-0,35	G_cor_w13	-0,37
S2_cor_w11	-0,31	S1_var_w7	-0,33	R_mea_w7	-0,35	G_cor_w15	-0,37
N_cor_w13	-0,32	S1_var_w5	-0,33	R_mea_w3	-0,35	sol	-0,39
S2_ent_w7	-0,32	S2_ent_w9	-0,33	R_mea_w5	-0,35	GARI	0,41
B_cor_w11	-0,32	S1_var_w3	-0,33	S1_mea_w11	-0,35	B_S2	0,41
N_cor_w15	-0,32	R_cor_w13	-0,34	G_cor_w9	-0,35	B_R	0,43
IPVI	0,32	R_cor_w15	-0,34	S2_mea_w9	-0,35	N_S1	0,43
NDVI	0,32	S2_ent_w11	-0,34	S1_mea_w9	-0,35	G_S2	0,45
S2_dis_w15	-0,32	S2_cor_w13	-0,35	S2_mea_w7	-0,35	N_S2	0,49
S2_cor_w9	-0,32	S1_mea_w15	-0,35	S2_ent_w13	-0,35	S1_S2	0,51

Os valores com correlação entre -0,3 e +0,3 foram excluídos da tabela por conta do número elevado de variáveis.

Fonte: Produção do autor.

Tabela 4.3 - Correlação de Pearson entre as variáveis Landsat e a biomassa viva.

Variável	Cor.	Variável	Cor.	Variável	Cor.	Variável	Cor.
S1_cor_w13	-0,3	S1_var_w5	-0,32	G_cor_w9	-0,33	S1_mea_w9	-0,34
B_cor_w11	-0,3	R_cor_w15	-0,32	S2_mea_w15	-0,33	S1_mea_w7	-0,35
S2_cor_w9	-0,31	S1_var_w3	-0,32	S2_mea_w13	-0,33	S1_mea_w5	-0,35
B_cor_w13	-0,31	S2_ent_w11	-0,32	S2_ent_w15	-0,33	G_cor_w13	-0,35
S1_cor_w15	-0,31	S2_cor_w13	-0,33	S2_mea_w11	-0,33	S1_mea_w3	-0,35
G_cor_w7	-0,31	R_mea_w13	-0,33	S2_mea_w9	-0,34	G_cor_w15	-0,35
S2_ent_w9	-0,31	R_mea_w11	-0,33	S2_mea_w7	-0,34	sol	-0,36
B_cor_w15	-0,31	R_mea_w15	-0,33	VARI	0,34	GARI	0,38
S1_var_w15	-0,32	R_mea_w3	-0,33	S2_mea_w5	-0,34	N_S1	0,41
S1_var_w13	-0,32	R_mea_w9	-0,33	S2_mea_w3	-0,34	B_S2	0,42
R_cor_w13	-0,32	R_mea_w7	-0,33	S1_mea_w15	-0,34	B_R	0,42
S1_var_w11	-0,32	R_mea_w5	-0,33	S1_mea_w13	-0,34	G_S2	0,44
S1_var_w9	-0,32	S2_ent_w13	-0,33	G_cor_w11	-0,34	N_S2	0,46
S1_var_w7	-0,32	S2_cor_w15	-0,33	S1_mea_w11	-0,34	S1_S2	0,48

Os valores com correlação entre -0,3 e +0,3 foram excluídos da tabela por conta do número elevado de variáveis.

Fonte: Produção do autor.

#### 4.4 Modelagem da biomassa

Utilizou-se duas formas de obter o modelo para prever a biomassa total e viva. A primeira forma foi a partir das variáveis pré-selecionadas baseado nas correlações apresentadas nas Tabelas 4.2 e 4.3. A segunda forma, não foi realizado pré-seleção das variáveis. Todas elas eram candidatas a comporem o modelo preditor de biomassa. A Tabela 4.4 apresenta o resultado dos modelos testados para a estimativa de biomassa para a região.

O modelo denominado de “Modelo I” para ambas as estimativas, é o modelo gerado a partir da pré-seleção das variáveis levando em consideração a correlação de Pearson. Enquanto o modelo “Modelo II” é o modelo obtido a partir da seleção automática a partir de todas as variáveis. As siglas \_T e \_V para ambos os modelos se referem a biomassa total e a biomassa viva, respectivamente.

Mesmo elaborando o modelo com as variáveis com maior correlação com a biomassa, este apresentou parâmetros piores do que o modelo que foi gerado

a partir de todas as variáveis, tanto para a biomassa viva quanto para a biomassa total. Isso pode estar relacionado ao fato de que uma certa variável pode não ter correlação direta com a biomassa, mas durante a modelagem ela melhora o ajuste do modelo.

O viés calculado para os modelos, que neste caso é a média do resíduo, foi pequeno, cerca de  $4,56 \times 10^{-12}$  Mg/ha para o Modelo I\_T e  $-4,37 \times 10^{-11}$  Mg/ha para o Modelo II\_T. Em relação a biomassa viva o Modelo I apresentou um viés maior do que o encontrado para o Modelo II (Tabela 4.1).

O erro entre os dois modelos para a biomassa total apresentou valores semelhantes, cerca de 50,61% e 47,99% no Modelo I e II, respectivamente. Na biomassa viva a diferença ficou em torno de 2,33% entre os dois modelos utilizados. O VIF foi considerado baixo e que não houve multicolinearidade entre os parâmetros da equação, pois como regra geral, um VIF maior que 10 indica que a multicolinearidade é alta (KUTNER et al., 2004).

Tabela 4.4 - Valores obtidos a partir dos modelos gerados para prever a biomassa com os dados orbitais.

	<b>Viés (Mg/ha)</b>	<b>RMSE (Mg/ha)</b>	<b>RMSE (%)</b>	<b>R<sup>2</sup></b>	<b>VIF</b>	
<b>Modelo I_T</b>	$4,56 \times 10^{-12}$	79,2	50,61	0,386	1,81	<b>Biomassa Total</b>
<b>Modelo II_T</b>	$-4,37 \times 10^{-11}$	75,1	47,99	0,448	1,82	
<b>Modelo I_V</b>	-3,29	88,8	54,55	0,364	1,75	<b>Biomassa Viva</b>
<b>Modelo II_V</b>	$-5,58 \times 10^{-12}$	77,5	52,22	0,414	1,71	

Fonte: Produção do autor.

A maior diferença entre os parâmetros para seleção do modelo foi o coeficiente de determinação (R<sup>2</sup>). Neste caso os modelos elaborados sem a pré-seleção das variáveis apresentaram o melhor resultado possibilitando a explicação de cerca de 44% da variação dos dados para a biomassa total e 41% para a biomassa viva.

Tanto para a biomassa total quanto para a biomassa viva, com base nos parâmetros avaliados para a seleção do modelo, optou-se pelo modelo ajustado a partir de todas as variáveis. Pois além de ter apresentado os melhores resultados, também exige um passo a menos durante o

processamento, tornando o processo mais simples de geração do modelo, principalmente quando se trabalha com muitas variáveis independentes e contribui para a capacidade computacional disponível para geração dos mapas de biomassa.

As equações 4.1 e 4.2 apresentam os coeficientes e as variáveis que estão contidas nos modelos selecionados para prever a biomassa. Os resíduos dos modelos escolhidos para prever a biomassa total e a biomassa viva estão apresentados na Figura 4.5a e Figura 4.5b, respectivamente.

Estimar a biomassa acima do solo em florestas tropicais a partir de imagens orbitais apresenta melhores estimativas em florestas em estágio inicial de sucessão do que em florestas maduras devido a menor complexidade da estrutura dos indivíduos (LU., 2005). Por outro lado, o LiDAR pode contribuir para as estimativas uma vez que é possível extrair informações do perfil vertical da floresta (HARDING et al., 2001; DRAKE; DUBAYAH; KNOX et al., 2002) e obter informações do sub-bosque contribuindo com as estimativas em florestas densas (TREUHAFI et al., 2009).

$$\begin{aligned}
 BAST = & -224,9380 * G_{mea_{w3}} - 269,6486 * B_{hom_{w13}} + 206,1871 \\
 & * S2_{hom_{w15}} - 542,6521 * MNLI + 148,7157 * \frac{B}{R} + 43,9937 \\
 & * \frac{N}{S2} - 30,5
 \end{aligned} \quad (4.1)$$

$$\begin{aligned}
 BASV = & -229,8793 * G_{mea_{w3}} + 45,7213 * B_{ent_{w11}} - 34,9321 * S2_{ent_{w13}} \\
 & - 493,4523 * MNLI + 167,7064 * \frac{B}{R} + 38,6359 * \frac{N}{S2} \\
 & - 98,76348
 \end{aligned} \quad (4.2)$$

Onde:  $G, B, N, S2$  são as bandas referentes aos comprimentos de onda do *Green, Blue, Nir, Swir2* do Landsat, respectivamente;  $mea, hom, ent$  são as texturas, média, homogeneidade e entropia;  $w3, w11, w13$  e  $w15$  são os tamanhos das janelas.  $MNLI$  é o índice *Modified Non-Linear Index*.

Enquanto nas imagens orbitais, em geral, os índices de vegetação podem reduzir parcialmente os impactos na reflectância causada por condições ambientais e sombras, melhorando assim a correlação entre os índices de vegetação e a biomassa, especialmente nos locais com estruturas complexas de vegetação (LU et al., 2004). Por outro lado, a textura é uma variável importante para melhorar o desempenho da estimativa de biomassa (KELSEY; NEFF, 2014).

Logicamente, nem todas as medidas de textura são úteis para obter informações de biomassa. Mesmo para a mesma medida de textura, a seleção do tamanho da janela e da banda espectral da imagem pode variar. Janelas muito pequenas podem exagerar na diferença entre as texturas e acabar gerando ruído nas imagens. Em contrapartida, janelas muito grandes acabam suavizando demais as feições e dificultam a extração de informações. Além disso, janelas grandes exigem maior tempo de processamento.

Na prática, não é trivial identificar quais tamanhos de janela e bandas de imagens são mais adequadas à um tópico de pesquisa específico, bem como a seleção das texturas mais adequadas para estimativa de biomassa. A seleção das variáveis mais adequadas é um passo crítico para o desenvolvimento de um modelo de estimativa de biomassa, que consiga explicar boa parte da variação dos dados e não gerar tantos resíduos.

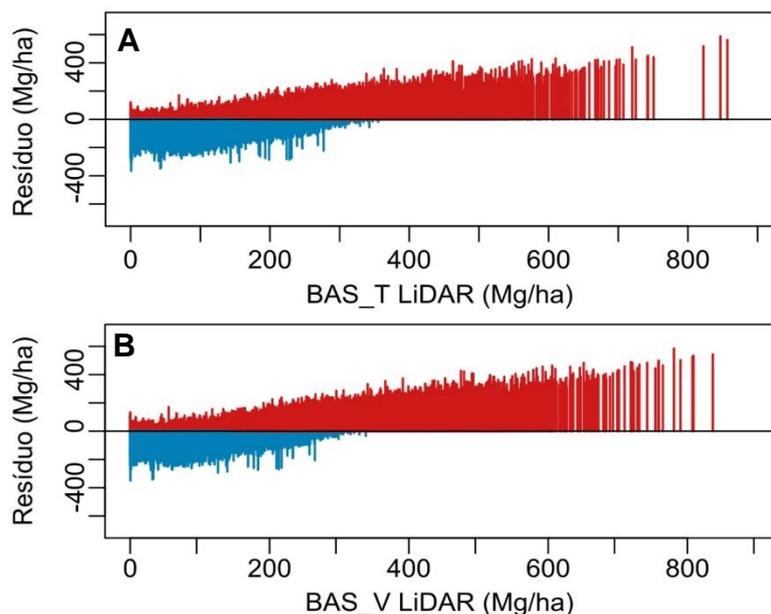
O resíduo positivo indica uma subestimação dos valores de biomassa, ou seja, o valor observado é maior do que aquele estimado. Nas áreas com maior biomassa, o potencial preditivo dos modelos acaba diminuindo devido a saturação, dificultando a predição em florestas tropicais intactas. Este é um problema já bastante discutido na literatura de desenvolvimento de modelos de biomassa em florestas tropicais (HOUGHTON et al., 2001; SAATCHI. et al., 2007; BACCINI et al., 2012).

Embora possa existir uma tendência dos modelos de subestimar a biomassa em áreas de floresta intacta ou de alta biomassa, os modelos não apresentaram viés significativo ( $p < 0,05$ ). Como grande parte das áreas florestais do estado do Mato Grosso são áreas que já passaram por algum

processo de degradação (com pouca presença de áreas intactas), utilizou-se os modelos selecionados para prever a biomassa total e a biomassa viva em todo o bioma amazônico encontrado no estado do Mato Grosso.

Estimar a biomassa acima do solo em florestas tropicais a partir de imagens orbitais apresenta melhores estimativas em florestas em estágio inicial de sucessão do que em florestas maduras devido a menor complexidade da estrutura dos indivíduos (LU., 2005). Por outro lado, o LiDAR pode contribuir para as estimativas uma vez que é possível extrair informações do perfil vertical da floresta (HARDING et al., 2001; DRAKE; DUBAYAH; KNOX et al., 2002) e obter informações do sub-bosque contribuindo com as estimativas em florestas densas (TREUHAFET et al., 2009).

Figura 4.5 - Resíduo para os modelos preditores da biomassa acima do solo total e viva.



Em vermelho o resíduo positivo e em azul o resíduo negativo. Em (A) o resíduo para a biomassa total; Em (B) o resíduo para a biomassa viva.

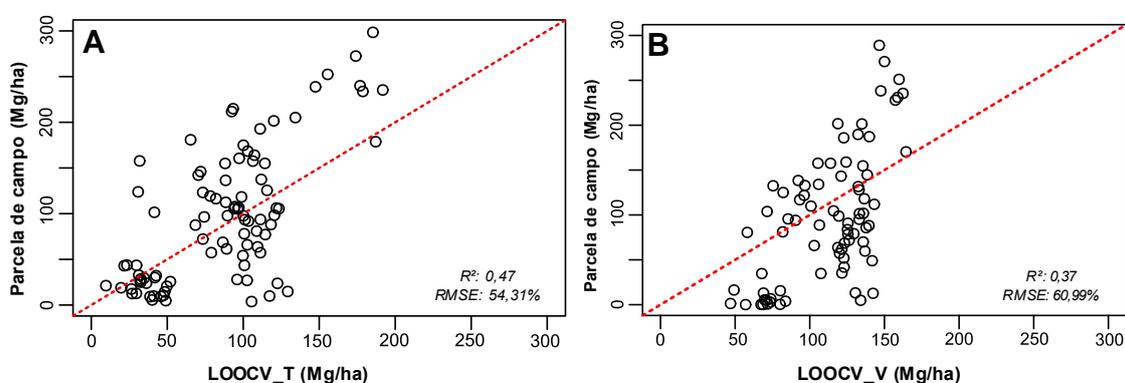
Fonte: Produção do autor.

Com as 93 parcelas de campo e por meio da técnica de validação cruzada “Deixa um de fora” ou acrônimo em inglês “*Leave One Out - LOO*” avaliou-se o

poder dos modelos em prever a biomassa. O resultado da validação para a biomassa total e viva da validação cruzada é apresentado na Figura 4.6.

A validação para biomassa total foi melhor do que a da biomassa viva, onde este último apresentou saturação para valores maiores que 160 Mg/ha. Pelo fato de a modelagem das árvores vivas excluir as árvores mortas, algumas parcelas, principalmente na área FNA, apresentaram valores de biomassa muito pequenos, em alguns casos, restou apenas 2 árvores em toda a parcela. Estes valores acabaram pesando na validação favorecendo a saturação.

Figura 4.6 - Validação LOO para os modelos de biomassa acima do solo total e viva.



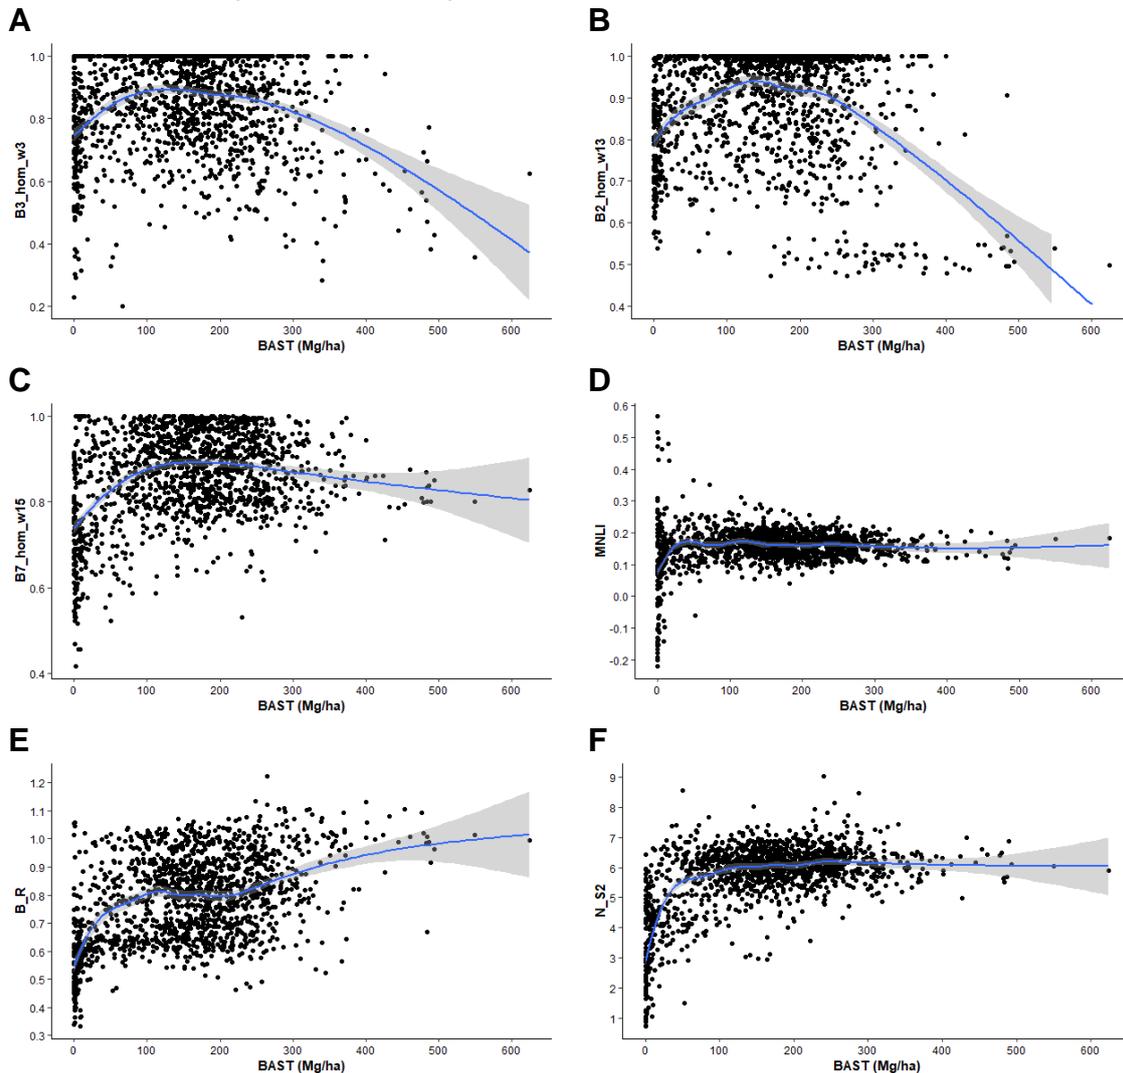
Em (A) o resultado para o modelo preditor da biomassa total. Em (B) o resultado para o modelo preditor da biomassa viva. A linha pontilhada vermelha é a relação 1:1.

Fonte: Produção do autor.

Embora a validação apresentou uma pequena saturação no modelo preditor da biomassa viva, esta saturação não teve um impacto direto na predição, dado que as áreas no Mato Grosso não apresentam biomassa tão alta. Já para a biomassa total esta saturação não ficou evidente. Com isso, a modelagem da biomassa a partir do processamento das imagens Landsat conseguiu compreender a variação da biomassa ao longo de áreas degradadas do bioma Amazônico no estado do Mato Grosso.

A relação entre a biomassa estimada e as variáveis que integram os modelos preditores da biomassa total e viva pode ser observada na Figura 4.7 e Figura 4.8, respectivamente.

Figura 4.7 - Relação entre a biomassa aérea acima do solo total e as variáveis que compõem o modelo preditor.

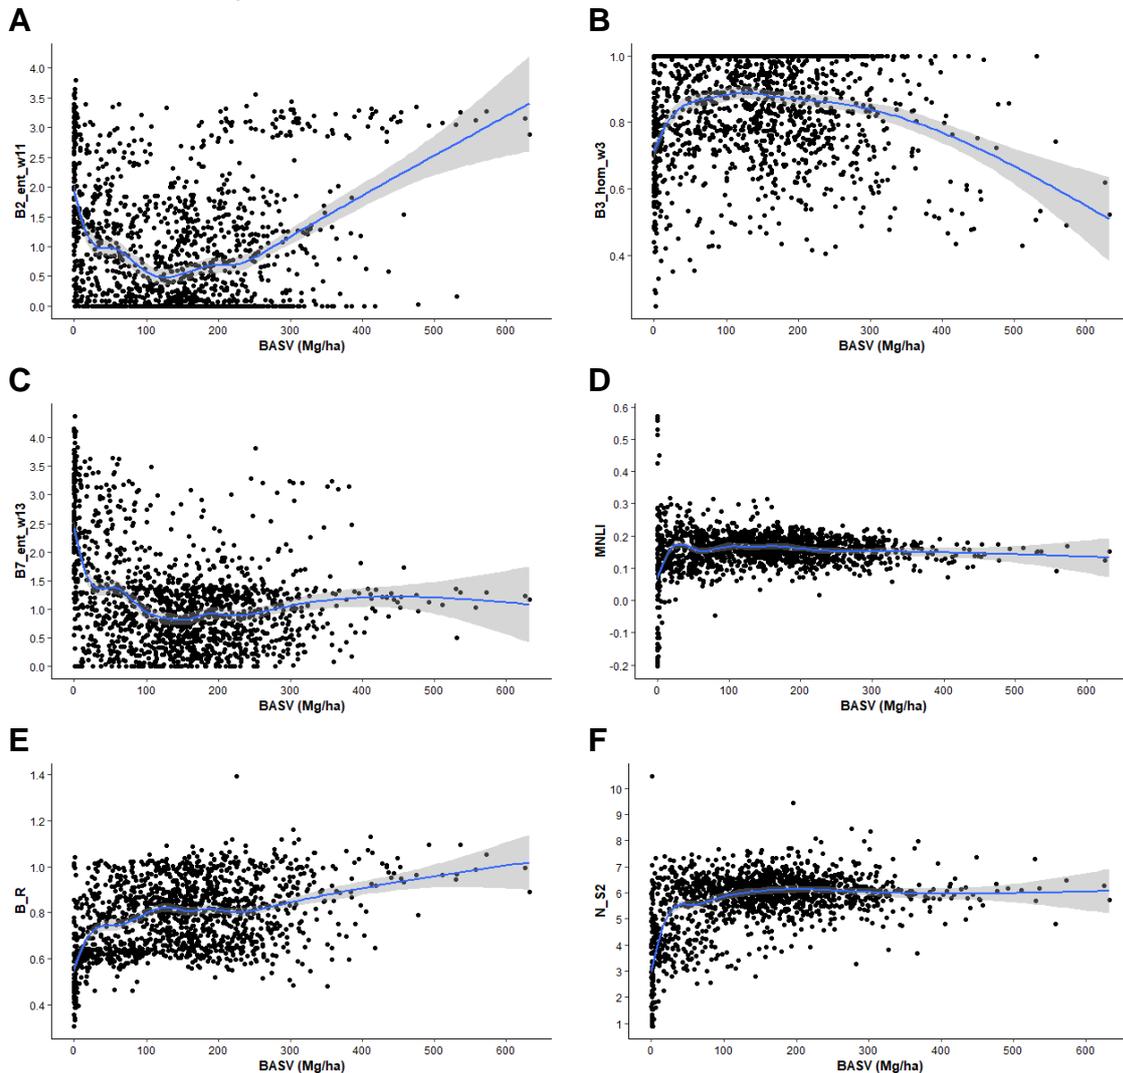


Em (A), (B), (C), (D), (E) e (F) a relação entra a biomassa aérea acima do solo total e as variáveis B3\_hom\_w3, B2\_hom\_w13, B7\_hom\_w15, MNLI, B\_R e N\_S2, respectivamente.

Fonte: Produção do autor.

A relação com as variáveis derivadas das imagens Landsat não apresentaram uma relação diretamente linear com a biomassa total. Entretanto estas variáveis quando utilizadas juntas conseguem explicar cerca de 47% na variação da biomassa total em áreas degradadas.

Figura 4.8 - Relação da biomassa aérea acima do solo viva com as variáveis que compõem o modelo.



Em (A), (B), (C), (D), (E) e (F) a relação entra a biomassa aérea acima do solo viva e as variáveis B2\_ent\_w11, B3\_hom\_w3, B7\_ent\_w13, MNLI, B\_R e N\_S2, respectivamente.

Fonte: Produção do autor.

No que se refere a biomassa acima do solo viva, a relação das variáveis para com a biomassa apresentou resultados semelhantes ao da biomassa total. As variáveis não apresentam relação diretamente linear com a biomassa, entretanto quando utilizadas conjuntamente auxiliam na modelagem da biomassa ao longo de áreas degradadas, permitindo explicar cerca de 37% da variação da biomassa naquelas áreas.

#### **4.5 Comparação com mapas de biomassa já publicados na literatura**

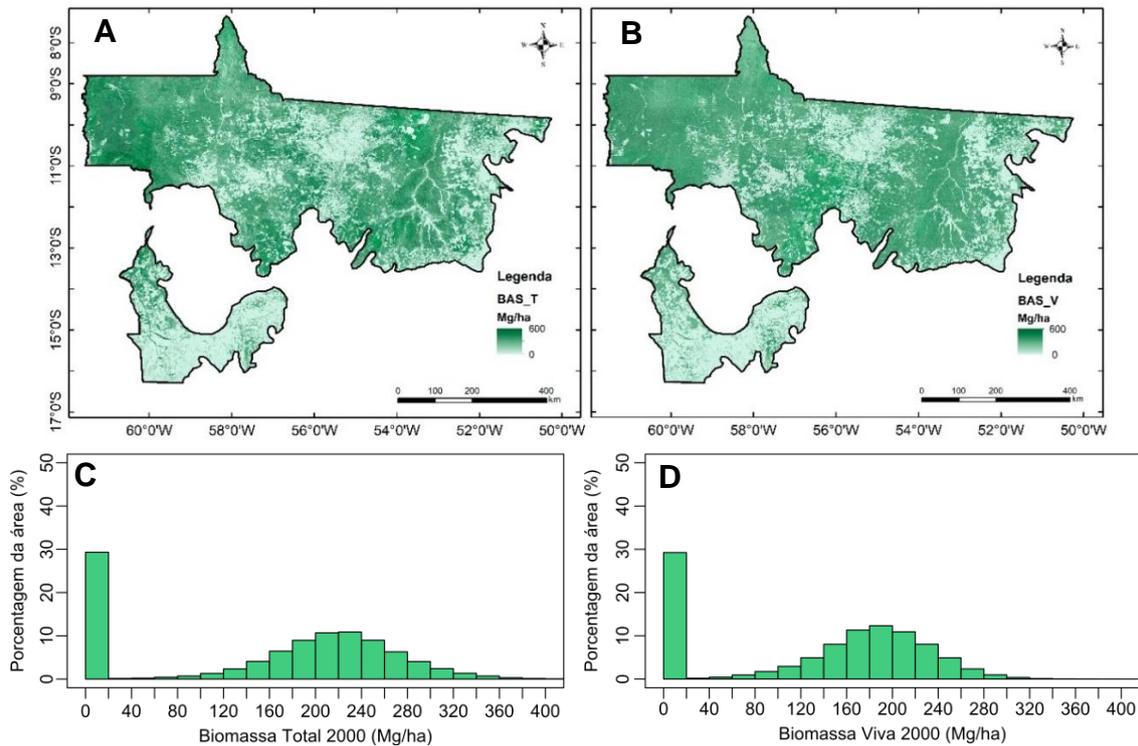
A Figura 4.9a e 4.9b apresentam os mapas de biomassa acima do solo total e viva, respectivamente, para a região compreendida pelo bioma amazônico no estado do Mato Grosso para o ano de 2000. O estoque de biomassa presente nas classes de biomassa apresentadas no histograma (Figura 4.9c e Figura 4.9d) mostram que a classe predominante é entre 200 e 240 Mg/ha para a biomassa total e 180 e 200 Mg/ha para a biomassa viva.

As áreas que apresentaram maior biomassa, são as áreas das unidades de conservação e terras indígenas. Destaca-se a área do Parque Indígena do Xingu, localizado na porção centro-leste, e as Terras Indígenas de Aripuanã, Zoró e Piripkura, localizadas no oeste do Mato Grosso.

As diversas espécies presentes nas florestas tropicais e suas estruturas dificultam a estimativa da biomassa, principalmente quando comparadas com florestas boreais, onde o número de espécies é menor e também a estrutura não é tão complexa (BENSON et al., 2011). Estudos realizados para a estimativa de biomassa em floresta boreal, a partir de dados do TanDEM-X e LiDAR, apresentaram um  $R^2$  de 0,89, RMSE de 19,6% para uma área com biomassa menor que 183 Mg/ha (ASKNE et al., 2017).

Frazier et al., (2014) utilizaram dados multitemporais do Landsat adquiridos a partir de 1984 até 2012 para estimar a biomassa em floresta boreal no Canadá, os autores obtiveram um  $R^2$  de 0,62 e RMSE 49% ao modelar a biomassa florestal em função das propriedades espectrais das imagens do Landsat. Florestas com estruturas menos complexas apresentam melhores estimativas quando comparadas com áreas com a estrutura mais complexa, como é o caso da Amazônia (LU et al., 2012).

Figura 4.9 - Biomassa estimada para o bioma Amazônia no estado do Mato Grosso.



Em (A) a Biomassa Acima do Solo Total (BAS\_T); E em (B) a Biomassa Acima do Solo Viva (BAS\_V). Em (C) e (D) os respectivos histogramas.

Fonte: Produção do autor.

O mapa de biomassa produzido para o bioma amazônico no estado do Mato Grosso foi comparado com os mapas pantropicais publicados por Saatchi et al. (2011) e Baccini et al. (2017). Estes mapas serão denominados como Mapa 1 e Mapa 2, respectivamente. Todos os mapas foram reamostrados para 1 km para torna possível a comparação pixel a pixel. Porém essa resolução não é sensível aos eventos de corte seletivo que ocorrem na floresta amazônica. A biomassa estimada com as imagens orbitais e LiDAR teve uma maior relação com o Mapa 2, com  $R^2$  de 0,68, enquanto a relação com o Mapa 1 apresentou  $R^2$  de 0,44, cerca de 24% menor (Figura 4.10a e 4.10b).

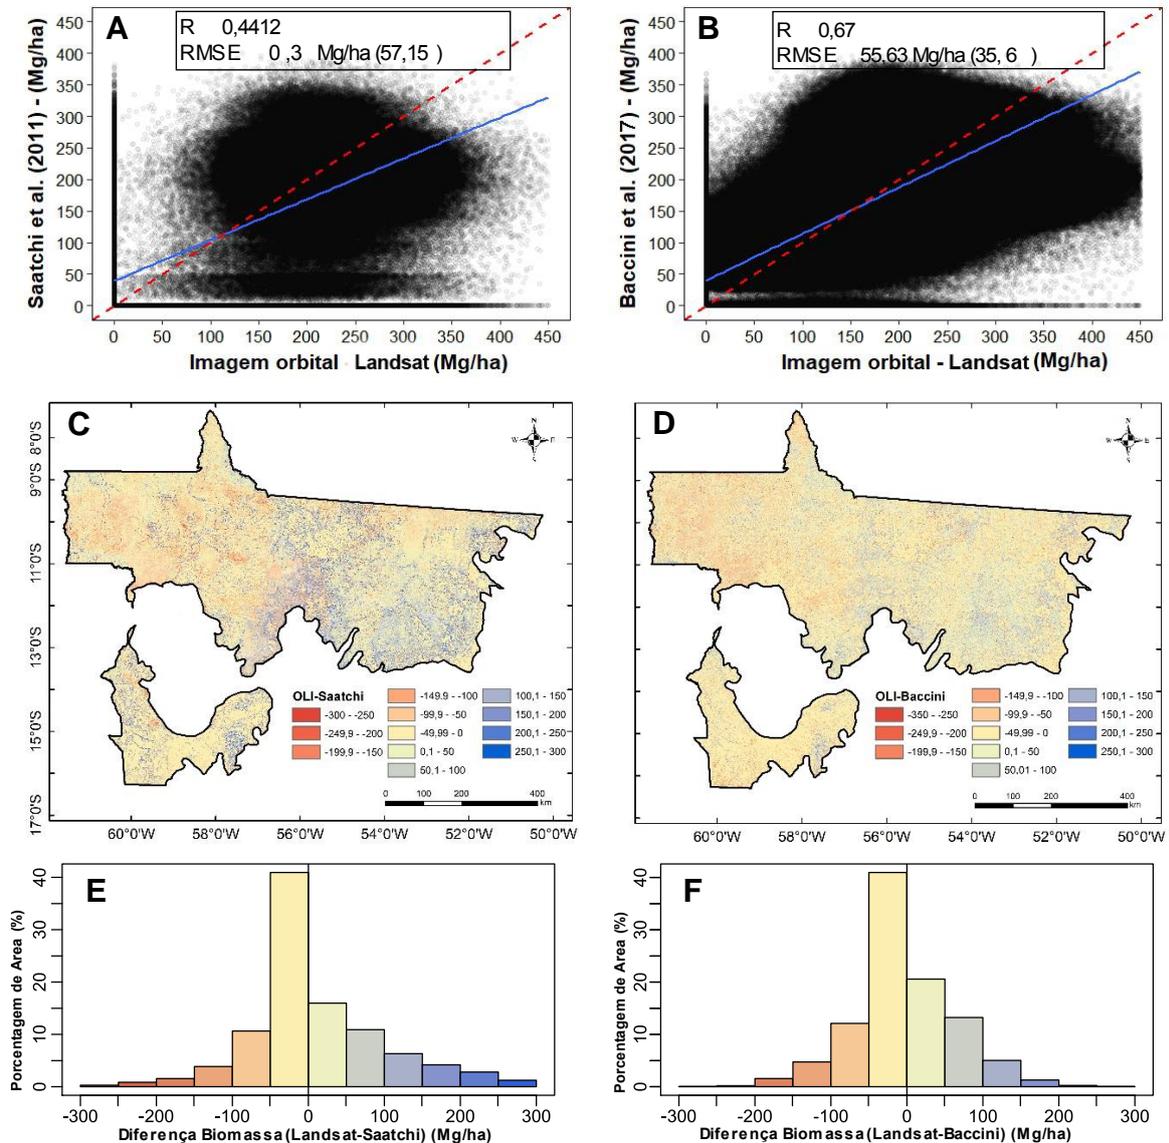
Além disso, as maiores diferenças estão entre o Mapa 1 e a biomassa estimada no presente estudo (Figura 4.10c e 4.10d). Em ambos os mapas (Mapa I e Mapa II), cerca de 40% de toda a área apresentou uma diferença negativa entre 0 e -50 Mg/ha (Figura 4.10e e 4.10f). Isto é, os valores de

biomassa nos mapas pantropicais apresentados na literatura são maiores do que o valor estimado a partir do modelo utilizando imagens Landsat deste trabalho.

A diferença entre os valores de biomassa e os mapas pantropicais pode estar associado aos remanescentes de floresta no estado do Mato Grosso, que em geral estão degradados. As parcelas de campos utilizadas na calibração da equação para prever a biomassa a partir dos dados LiDAR, desenvolvida por Longo et al., (2016), foram parcelas em sua maioria alocadas em áreas degradadas.

Para 16% de toda a área, a diferença entre a biomassa estimada com as imagens orbitais do Landsat e o Mapa 1 ficou entre 0 e 50 Mg/ha. Em relação a biomassa estimada com as imagens orbitais do Landsat e o Mapa 2, a área compreendida pela diferença, cujo os valores estão entre 0 e 50 Mg/ha abrangem 21% de toda a área, cerca de 5% a mais que a diferença com o Mapa 1. Isso significa que, para 16% e 21% da área de estudo a biomassa estimada a partir dos dados orbitais é maior que os Mapas 1 e 2, respectivamente.

Figura 4.10 - Comparação com os mapas de biomassa elaborado por Saatchi et al. (2011) e Baccini et al. (2017).



Em (A), a comparação da biomassa estimada a partir das imagens espectrais do Landsat com o mapa de biomassa de Saatchi et al., (2011) e do Baccini et al., (2017), respectivamente. A linha contínua azul em (A) e (B) representa a relação entre os dois mapas e a linha pontilhada vermelha é a relação 1:1. Em (C) e (D) são os mapas da diferença entre a biomassa obtida a partir do processamento das imagens Landsat e os dados de Saatchi et al., (2011) e do Baccini et al., (2017) respectivamente. (E) e (F) apresentam os histogramas da diferença entre os mapas de biomassa expressos em porcentagem

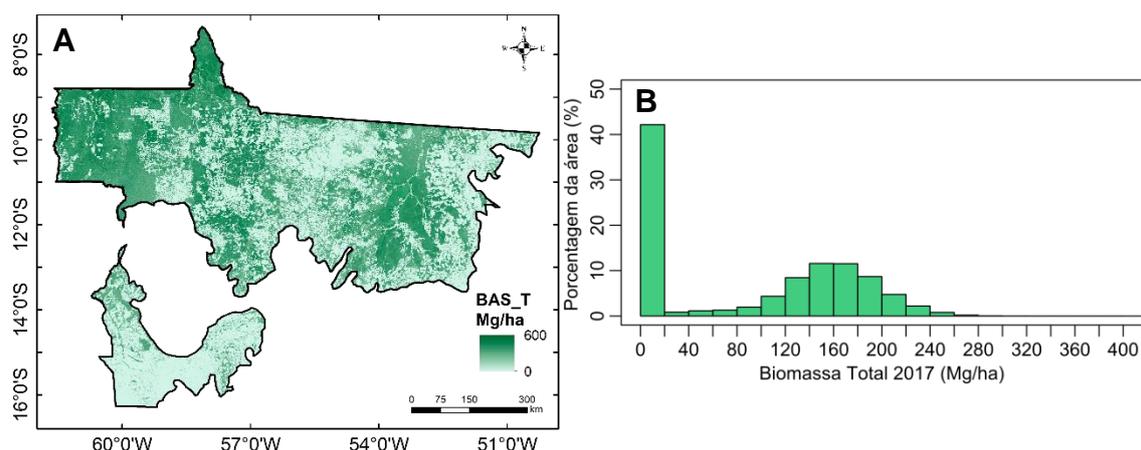
Fonte: Produção do autor.

#### 4.6 Geração do mapa de biomassa para 2017

O modelo ajustado a partir do processamento dos dados do Landsat foi utilizado para estimar a biomassa para o ano de 2017. Para isso utilizou-se imagens de 2017, da época seca e, preferencialmente livre de nuvens.

O estoque de biomassa acima do solo total no estado no Mato Grosso na área compreendida pelo bioma Amazônia (Figura 4.11a) é de aproximadamente 4,41 Pg com uma biomassa média por hectare de 155,12 Mg ( $\pm 44,91$  Mg/ha). Além disso, a biomassa ficou mais concentrada em torno de 140 e 180 Mg/ha. O que difere bastante de áreas de floresta intacta em outras regiões da Amazônia, por exemplo em florestas intactas densa na porção sul amazônica os valores variam entre 298 a 533 Mg/ha (CUMMINGS et al., 2002).

Figura 4.11 - Distribuição da biomassa total acima do solo para o bioma Amazônia no estado do Mato Grosso para o ano de 2017.



Em (A) o mapa da distribuição espacial da biomassa ao longo do bioma Amazônia no estado do Mato Grosso. Em (B) o histograma da biomassa.

Fonte: Produção do autor.

As áreas com menor biomassa são um retrato da exploração e da degradação da floresta. No estado do Mato Grosso entre 2012 e 2013 a área de exploração de madeira aumentou 53%, cerca de 303.585 ha (SILGUEIRO et al., 2015). Além disso, o sistema de fiscalização e emissão das licenças para manejo florestal apresenta falhas e as leis podem ser burladas. Ou seja, mesmo em

áreas onde há a liberação para o manejo florestal, pode haver derrubada ilegal de madeira.

Cabe ressaltar, o aumento de aproximadamente 10% na classe de biomassa de 0 e 20 Mg/ha entre os anos 2000 e 2017 (ver Figura 4.9c e 4.11b). Como as áreas de solo exposto estão nesta classe (Biomassa = 0 Mg), pode-se dizer que houve uma redução de aproximadamente 10% de floresta no intervalo dos 17 anos. Segundo o PRODES, entre 2000 e 2017 o desmatamento acumulado no estado do Mato Grosso, foi de 72.039 km<sup>2</sup> (INPE, 2017) o que equivale a 7,38% de toda a área do Mato Grosso. Fato importante que o PRODES leva em consideração todo o estado do MT e não apenas o bioma Amazônia.

Em adição, houve a redução da biomassa nas demais classes de biomassa para 2017 em relação a 2000. O que já era esperado, uma vez que ocorreu a redução nas áreas de floresta. Esta redução de biomassa no bioma Amazônia no estado do Mato Grosso corrobora os efeitos da degradação florestal e desmatamento desenfreados que vem ocorrendo na região.

## 5 CONSIDERAÇÕES FINAIS

A caracterização florística e estrutural da vegetação apresentou as informações sob a tipologia florestal analisada, além de apresentar a distribuição espacial destas parcelas. Esta etapa do trabalho forneceu informações a respeito da quantidade de indivíduos por área, bem como o nível de degradação que determinado ambiente pode estar devido a presença de determinadas espécies.

No processo de modelagem, a seleção das variáveis é um processo crucial para a elaboração de bons modelos. Neste contexto a comparação dos dois métodos utilizados neste estudo mostrou que, ao utilizar todas as variáveis na seleção os resultados apresentaram modelos melhores do que os obtidos com a pré-seleção das variáveis baseados na Correlação de Pearson.

Um ponto importante é que uma variável que apresente alta correlação com a biomassa pode não ser tão significativa no modelo preditor e outra variável que não seja tão correlacionada com a biomassa pode melhorar o poder preditivo do modelo sem ocasionar multicolinearidade. O fato de não ser necessário realizar a pré-seleção das variáveis deixa o procedimento mais simples de ser concluído. Embora a utilização de muitas variáveis independentes candidatas a comporem o modelo não dificulta o processo computacional, dado que esta etapa é relativamente rápida.

A utilização de índices de vegetação, razões entre bandas e dados de textura derivados de imagens Landsat contribuiu para a estimativa de biomassa e tornou possível a extrapolação para a região amazônica do estado do Mato Grosso.

A integração entre dados LiDAR multitemporais com imagens Landsat proporcionou a elaboração de modelos genéricos de estimativa de biomassa para o bioma Amazônia no estado do Mato Grosso, o qual permite sua aplicação em diferentes datas. Além disto, o modelo conseguiu explicar cerca de 47% da variação da biomassa total na área. Isso permitiu aplicar o modelo em imagens referentes ao ano 2000 e comparar o resultado com os mapas de biomassa já publicados na literatura. O fato de o valor ser negativo significa

que os valores nos Mapas I e II foram maiores do que na biomassa estimada a partir do modelo desenvolvido neste estudo.

A biomassa menor é decorrência, em parte, das parcelas de campo utilizadas para calibrar a equação preditora da biomassa a partir dos dados LiDAR. No presente trabalho, as parcelas de campo são provenientes de áreas degradadas e retratam a floresta encontrada no estado do Mato Grosso, enquanto o conjunto de dados utilizados para calibração dos modelos descritos na literatura varia (desde inventários, até nível de dados de sensoriamento remoto – ópticos, RADAR, LiDAR).

A partir da aplicação do modelo nas imagens provenientes do ano 2017, foi possível acessar a distribuição e estoque de biomassa atual para o estado do Mato Grosso. Entre os 17 anos, as maiores modificações foram encontradas na classe de 0 a 50 Mg/ha, sendo que, nesta classe é onde são encontradas mais áreas afetadas pelo desmatamento (biomassa = 0 Mg/ha). Ou seja, os resultados sugerem que durante o período ocorreu uma redução em termos de biomassa para a área analisada, corroborando com outras estimativas, como o PRODES.

Para trabalhos futuros, recomenda-se a utilização de dados de textura e índices de vegetação para a estimativa de biomassa a partir de imagens orbitais. Além disto, imagens Landsat se mostraram satisfatórias para estimar a biomassa em áreas degradadas, e recomenda-se o uso de outros sensores para cálculo destas estimativas, como aqueles derivados do satélite Sentinel-2, por exemplo. A utilização de dados LiDAR foi uma abordagem importante para a calibração do modelo e obtenção de resultados satisfatórios na estimativa de biomassa. Estes dados permitiram aumentar o número de amostras para o cálculo de biomassa, contribuindo diretamente para um melhor ajuste na etapa de modelagem.

Desta forma, este trabalho visou o desenvolvimento de um modelo genérico de estimativa de biomassa para áreas degradadas na Amazônia brasileira, e recomenda-se sua utilização em uma série temporal de dados orbitais a fim de

explorar as análises e estudos que abordem a dinâmica de biomassa e carbono.

No entanto, análises futuras exigem uma avaliação mais rigorosa sobre a propagação do erro associado as estimativas da biomassa utilizando dados de sensoriamento remoto orbital óptico, bem como os processos que podem contribuir com incertezas durante estas estimativas.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALENCAR, A. A.; BRANDO, P. M.; ASNER, G. P.; PUTZ, F. E. Landscape fragmentation, severe drought, and the new Amazon forest fire regime. **Ecological Applications**, v. 25, n. 6, p. 1493–1505, 2015.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. DE M.; GERD, S. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- ANDERSEN, H. E.; REUTE RUCH, S. E.; MCGAUGHEY, R. J.; D'OLIVEIRA, M. V. N.; KELLER, M. Monitoring selective logging in western Amazonia with repeat lidar flights. **Remote Sensing of Environment**, v. 151, p. 157–165, 2014.
- ANDERSON, L. O.; SHIMABUKURO, Y. E.; LIMA, A.; MEDEIROS, J. S. Mapeamento da cobertura da terra do Estado do Mato Grosso através da utilização de dados Multitemporais do Sensor Modis. **Geografia**, v. 30, n. 12, p. 365–380, 2005.
- ARAGÃO, L. E. O. C. et al. 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions. **Nature Communications**, v. 9, n. 1, p. 1–12, 2018.
- ARAGÃO, L. E. O. C.; MALHI, Y.; ROMAN-CUESTA, R. M.; SAATCHI, S.; ANDERSON, L. O.; SHIMABUKURO, Y. E. Spatial patterns and fire response of recent Amazonian droughts. **Geophysical Research Letters**, v. 34, n. 7, p. L07701, 2007.
- ARAGÃO, L. E. O. C.; POULTER, B.; BARLOW, J. B.; ANDERSON, L. O.; MALHI, Y.; SAATCHI, S.; PHILLIPS, O. L.; GLOOR, E. Environmental change and the carbon balance of Amazonian forests. **Biological Reviews**, v. 89, n. 4, p. 913–931, 2014.
- ARAUJO, R. A.; COSTA, R. B.; FELFILI, J. M.; KUNTZ, I. G.; SOUSA, R. A. T. DE M. E.; DORVAL, A. Florística e estrutura de fragmento florestal em área de transição na Amazônia Matogrossense no município de Sinop. **Acta Amazonica**, v. 39, n. 4, p. 865–877, 2009.
- ASKNE, J. I. H.; SOJA, M. J.; ULANDER, L. M. H. Biomass estimation in a boreal forest from TanDEM-X data, lidar DTM, and the interferometric water cloud model. **Remote Sensing of Environment**, v. 196, p. 265–278, 2017.
- ASNER, G. P.; KELLER, M.; PEREIRA, R.; ZWEEDE, J. C. Remote sensing of selective logging in Amazonia: Assessing limitations based on detailed field observations, Landsat ETM+, and textural analysis. **Remote Sensing of Environment**, v. 80, n. 3, p. 483–496, 2002.
- ASNER, G. P.; KNAPP, D. E.; BROADBENT, E. N.; OLIVEIRA, P. J. C.;

KELLER, M.; SILVA, J. N. Selective logging in the Brazilian Amazon. **Science**, v. 310, n. 5747, p. 480–482, 2005.

ASNER, G. P.; POWELL, G. V. N.; MASCARO, J.; KNAPP, D. E.; CLARK, J. K.; JACOBSON, J.; KENNEDY-BOWDOIN, T.; BALAJI, A.; PAEZ-ACOSTA, G.; VICTORIA, E.; SECADA, L.; VALQUI, M.; HUGHES, R. F. High-resolution forest carbon stocks and emissions in the Amazon. **Proceedings of the National Academy of Sciences**, v. 107, n. 38, p. 16738–16742, 2010.

AVITABILE, V. et al. An integrated pan-tropical biomass map using multiple reference datasets. **Global Change Biology**, v. 22, n. 4, p. 1406–1420, 2016.

BACCINI, A.; GOETZ, S. J.; WALKER, W. S.; LAPORTE, N. T.; SUN, M.; SULLA-MENASHE, D.; HACKLER, J.; BECK, P. S. A.; DUBAYAH, R.; FRIEDL, M. A.; SAMANTA, S.; HOUGHTON, R. A. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature Climate Change**, v. 2, n. 3, p. 182–185, 2012.

BACCINI, A.; WALKER, W.; CARVALHO, L.; FARINA, M.; SULLA-MENASHE, D.; HOUGHTON, R. A. Tropical forests are a net carbon source based on aboveground measurements of gain and loss. **Science**, v. 358, n. 6360, p. 230–234, 2017.

BALCH, J. K.; NEPSTAD, D. C.; CURRAN, L. M.; BRANDO, P. M.; PORTELA, O.; GUILHERME, P.; REUNING-SCHERER, J. D.; DE CARVALHO, O. Size, species, and fire behavior predict tree and liana mortality from experimental burns in the Brazilian Amazon. **Forest Ecology and Management**, v. 261, n. 1, p. 68–77, 2011.

BALCH, J. R. K.; NEPSTAD, D. C.; BRANDO, P. M.; CURRAN, L. M.; PORTELA, O.; DE CARVALHO, O.; LEFEBVRE, P. Negative fire feedback in a transitional forest of southeastern Amazonia. **Global Change Biology**, v. 14, n. 10, p. 2276–2287, 2008.

BANNARI, A.; ASALHI, H.; TEILLET, P. M. Transformed Difference Vegetation Index (TDVI) for Vegetation Cover Mapping. v. 5, p. 3053–3055, 2002.

BANNARI, A.; MORIN, D.; BONN, F.; HUETE, A. R. A review of vegetation indices. **Remote Sensing Reviews**, v. 13, n. 1, p. 95–120, 1995.

BENSON, M.; PIERCE, L.; BERGEN, K.; SARABANDI, K.; KAILAI ZHANG; RYAN, C. Forest structure estimation using SAR, LiDAR, and optical data in the Canadian Boreal forest. p. 2609–2612, 2011.

BERENQUER, E.; FERREIRA, J.; GARDNER, T. A.; ARAGÃO, L. E. O. C.; DE CAMARGO, P. B.; CERRI, C. E.; DURIGAN, M.; DE OLIVEIRA, R. C.; VIEIRA, I. C. G.; BARLOW, J. A large-scale field assessment of carbon stocks in human-modified tropical forests. **Global Change Biology**, v. 20, n. 12, p. 3713–3726, 2014.

BETTS, R. A.; MALHI, Y.; ROBERTS, J. T. The future of the Amazon: new perspectives from climate, ecosystem and social sciences. **Philosophical Transactions of the Royal Society B: Biological Sciences**, v. 363, n. 1498, p. 1729–1735, 2008.

BRANDO, P. M.; BALCH, J. K.; NEPSTAD, D. C.; MORTON, D. C.; PUTZ, F. E.; COE, M. T.; SILVERIO, D.; MACEDO, M. N.; DAVIDSON, E. A.; NOBREGA, C. C.; ALENCAR, A.; SOARES-FILHO, B. S. Abrupt increases in Amazonian tree mortality due to drought-fire interactions. **Proceedings of the National Academy of Sciences**, v. 111, n. 17, p. 6347–6352, 2014.

BRANDO, P. M.; OLIVERIA-SANTOS, C.; ROCHA, W.; CURY, R.; COE, M. T. Effects of experimental fuel additions on fire intensity and severity: unexpected carbon resilience of a neotropical forest. **Global change biology**, v. 22, n. 7, p. 2516–2525, 2016.

BROWN, I. F.; NEPSTAD, D. C.; PIRES, I. D. O.; LUZ, L. M.; ALECHANDRE, A. S. Carbon Storage and Land-use in Extractive Reserves, Acre, Brazil. **Environmental Conservation**, v. 19, n. 4, p. 307–315, 1992.

CARREIRAS, J. M. B.; SHIMABUKURO, Y. E.; PEREIRA, J. M. C. Fraction images derived from SPOT-4 VEGETATION data to assess land-cover change over the State of Mato Grosso, Brazil. **International Journal of Remote Sensing**, v. 23, n. 23, p. 4979–4983, 2002.

CHAMPION, I.; DUBOIS-FERNANDEZ, P.; GUYON, D.; COTTREL, M. Radar image texture as a function of forest stand age. **International Journal of Remote Sensing**, v. 29, n. 6, p. 1795–1800, 2008.

CHAVE, J.; COOMES, D.; JANSEN, S.; LEWIS, S. L.; SWENSON, N. G.; ZANNE, A. E. Towards a worldwide wood economics spectrum. **Ecology Letters**, v. 12, n. 4, p. 351–366, 2009.

CHEN, B.; SHI, S.; GONG, W.; ZHANG, Q.; YANG, J.; DU, L.; SUN, J.; ZHANG, Z.; SONG, S. Multispectral LiDAR point cloud classification: A two-step approach. **Remote Sensing**, v. 9, n. 4, p. 1–17, 2017.

CHEN, J. M. Evaluation of vegetation indices and a modified simple ratio for boreal applications. **Canadian Journal of Remote Sensing**, v. 22, n. 3, p. 229–242, 1996.

CRIPPEN, R. E. Calculating the vegetation index faster. **Remote Sensing of Environment**, v. 34, n. 1, p. 71–73, 1990.

CUMMINGS, D. L.; BOONE KAUFFMAN, J.; PERRY, D. A.; FLINT HUGHES, R. Aboveground biomass and structure of rainforests in the southwestern Brazilian Amazon. **Forest Ecology and Management**, v. 163, n. 1–3, p. 293–307, 2002.

D'OLIVEIRA, M. V. N.; REUTE UCH, S. E.; MCGAUGHE , R. J.; ANDERSEN, H. E. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, v. 124, p. 479–491, 2012.

DEVISSCHER, T.; MALHI, Y.; ROJAS LANDÍVAR, V. D.; OLIVERAS, I. Understanding ecological transitions under recurrent wildfire: A case study in the seasonally dry tropical forests of the Chiquitania, Bolivia. **Forest Ecology and Management**, v. 360, p. 273–286, 2016.

DIAS-FILHO, M. B. **Desafios e Perspectivas na Recuperação de Pastagens Degradadas na Amazônia**. 1. ed. Belém - PA: Embrapa Amazônia Ocidental, 2015.

DRAKE, J. B.; DUBAYAH, R. O.; CLARK, D. B.; KNOX, R. G.; BLAIR, J. B.; HOFTON, M. A.; CHAZDON, R. L.; WEISHAMPEL, J. F.; PRINCE, S. D. Estimation of tropical forest structural characteristics using large-footprint lidar. v. 79, p. 305–319, 2002.

DRAKE, J. B.; DUBAYAH, R. O.; KNOX, R. G.; CLARK, D. B.; BLAIR, J. B.; RICA, C. Sensitivity of large-footprint lidar to canopy structure and biomass in a neotropical rainforest. v. 81, p. 378–392, 2002.

DUBAYAH, R. O.; DRAKE, J. B. Lidar Remote Sensing for Forestry. **Journal of Forestry**, p. 44–46, 2000.

DUBE, T.; MUTANGA, O. Investigating the robustness of the new Landsat-8 Operational Land Imager derived texture metrics in estimating plantation forest aboveground biomass in resource constrained areas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 12–32, 2015.

ECKERT, S. Improved Forest Biomass and Carbon Estimations Using Texture Measures from WorldView-2 Satellite Data. **Remote Sensing**, p. 810–829, 2012.

ELLIS, P.; GRISCOM, B.; WALKER, W.; GONÇALVES, F.; CORMIER, T. Mapping selective logging impacts in Borneo with GPS and airborne lidar. **Forest Ecology and Management**, v. 365, p. 184–196, 2016.

EMBRAPA. Sistema brasileiro de classificação de solos. **Embrapa Solos-Livros técnicos (INFOTECA-E)**, 2013.

FAO. Assessing forest degradation: Towards the development of globally applicable guidelines. **Forest Resources Assessment**, p. 99, 2011.

FAO. Forest Resources Assessment 2015: Terms and Definitions. **FAO report**, p. 36, 2012.

FARR, T.; ROSEN, P.; CARO, E.; CRIPPEN, R.; DUREN, R.; HENSLEY, S.;

KOBRICK, M.; PALLER, M.; RODRIGUEZ, E.; ROTH, L.; SEAL, D.; SHAFFER, S.; SHIMADA, J.; UMLAND, J.; WERNER, M.; OSKIN, M.; BURBANK, D.; ALSDORF, D. The shuttle radar topography mission. **Reviews of Geophysics**, v. 45, n. 2005, p. 1–33, 2007.

FEARNSIDE, P. M.; RIGHI, C. A.; GRAÇA, P. M. L. DE A.; KEIZER, E. W. H.; CERRI, C. C.; NOGUEIRA, E. M.; BARBOSA, R. I. Biomass and greenhouse-gas emissions from land-use change in Brazil's Amazonian "arc of deforestation": The states of Mato Grosso and Rondônia. **Forest Ecology and Management**, v. 258, n. 9, p. 1968–1978, 2009.

FELFILI, J. M.; VENTUROLI, F. Tópicos em análise de vegetação. **Comunicações técnicas florestais**, v. 2, n. 2, p. 1–25, 2000.

FERRAZ, A.; SAATCHI, S.; MALLET, C.; JACQUEMOUD, S.; GONÇALVES, G.; SILVA, C. A.; SOARES, P.; TOMÉ, M.; PEREIRA, L. Airborne lidar estimation of aboveground forest biomass in the absence of field inventory. **Remote Sensing**, v. 8, n. 8, p. 1–18, 2016.

FERREIRA, J.; LENNOX, G. D.; GARDNER, T. A.; THOMSON, J. R.; BERENQUER, E.; LEES, A. C.; MAC NALLY, R.; ARAGÃO, L. E. O. C.; FERRAZ, S. F. B.; LOUZADA, J.; MOURA, N. G.; OLIVEIRA, V. H. F.; PARDINI, R.; SOLAR, R. R. C.; VIEIRA, I. C. G.; BARLOW, J. Carbon-focused conservation may fail to protect the most biodiverse tropical forests. **Nature Climate Change**, p. 1–6, 2018.

FOLEY, J. A.; ASNER, G. P.; COSTA, M. H.; COE, M. T.; DEFRIES, R.; GIBBS, H. K.; HOWARD, E. A.; OLSON, S.; PATZ, J.; RAMANKUTTY, N.; SNIDER, P. Amazonia revealed : forest degradation and loss of Amazonia revealed : forest degradation and loss of ecosystem goods and services in the Amazon Basin. n. April, p. 25–32, 2016.

FRAZIER, R. J.; COOPS, N. C.; WULDER, M. A.; KENNEDY, R. Characterization of aboveground biomass in an unmanaged boreal forest using Landsat temporal segmentation metrics. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 137–146, 2014.

GALFORD, G. L.; MELILLO, J. M.; KICKLIGHTER, D. W.; CRONIN, T. W.; CERRI, C. E.; MUSTARD, J. F.; CERRI, C. C. Greenhouse gas emissions from alternative futures of deforestation and agricultural management in the southern Amazon. **Proceedings of the National Academy of Sciences**, v. 107, n. 46, p. 19649–19654, 2010.

GARCIA, M.; SAATCHI, S.; FERRAZ, A.; SILVA, C.; USTIN, S.; KOLTUNOV, A.; BALZTER, H. Impact of data model and point density on aboveground forest biomass estimation from airborne LiDAR. **Carbon Balance and Management**, v. (in press), p. 1–18, 2017.

GITELSON, A. A.; STARK, R.; GRITS, U.; RUNDQUIST, D.; KAUFMAN, Y.;

DERRY, D. Vegetation and soil lines in visible spectral space: A concept and technique for remote estimation of vegetation fraction. **International Journal of Remote Sensing**, v. 23, n. 13, p. 2537–2562, 2002.

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289–298, 1996.

GITELSON, A. A.; MERZLYAK, M. N. Remote sensing of chlorophyll concentration in higher plant leaves. **Advances in Space Research**, v. 22, n. 5, p. 689–692, 1998.

GOEL, N. S.; QIN, W. Influences of canopy architecture on relationships between various vegetation indices and LAI and Fpar: A computer simulation. **Remote Sensing Reviews**, v. 10, n. 4, p. 309–347, 1994.

GOETZ, S. J.; BACCINI, A.; LAPORTE, N. T.; JOHNS, T.; WALKER, W.; KELLNDORFER, J.; HOUGHTON, R. A.; SUN, M. Mapping and monitoring carbon stocks with satellite observations: A comparison of methods. **Carbon Balance and Management**, v. 4, p. 1–7, 2009.

GOLFARI, L.; CASER, R. L.; MOURA, V. P. G. **Zoneamento ecológico esquemático para reflorestamento no Brasil**. Belo Horizonte, MG: PRODEPEF, PNUD/FAO/IBDF/BRA-45, 1978.

GONÇALVES, F.; TREUHAFT, R.; LAW, B.; ALMEIDA, A.; WALKER, W.; BACCINI, A.; DOS SANTOS, J.; GRAÇA, P. Estimating Aboveground Biomass in Tropical Forests: Field Methods and Error Analysis for the Calibration of Remote Sensing Observations. **Remote Sensing**, v. 9, n. 1, p. 47, 2017.

HANSEN, E. H.; GOBAKKEN, T.; NÆSSET, E. Effects of pulse density on digital terrain models and canopy metrics using airborne laser scanning in a tropical rainforest. **Remote Sensing**, v. 7, n. 7, p. 8453–8468, 2015.

HANSEN, M. C. C. et al. High-Resolution Global Maps of 21st-Century Forest Cover Change. **Science**, v. 342, n. November, p. 850–854, 2013.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, p. 610–621, 1973.

HARDING, D. J.; LEFSKY, M. A.; PARKER, G. G.; BLAIR, J. B. Laser altimeter canopy height profiles methods and validation for closed-canopy, broadleaf forests. **Remote Sensing of Environment**, v. 76, n. 3, p. 283–297, 2001.

HENTZ, Â. M. K.; RUZA, M. S.; CORTE, A. P. D.; SANQUETTA, C. R. Técnicas De Sensoriamento Remoto Para Estimativa De Biomassa Em Ambientes Florestais. **Enciclopédia Biosfera**, v. 10, n. 18, p. 2810, 2014.

HIGUCHI, N.; CARVALHO-JR, J. Fitomassa e conteúdo de carbono de espécies arbóreas da Amazônia. In: SEMINÁRIO EMISSÃO X SEQÜESTRO DE CO2: UMA NOVA OPORTUNIDADE DE NEGÓCIOS PARA O BRASIL. 1994, **Anais...** . [S.l: s.n.], p. 125–153, 1994.

HIGUCHI, N.; CHAMBERS, J.; SANTOS, J. DOS. Dinâmica e balanço do carbono da vegetação primária da Amazônia Central. **Floresta**, v. 34, n. 3, p. 295–304, 2005.

HOUGHTON, R. A.; HOUSE, J. I.; PONGRATZ, J.; VAN DER WERF, G. R.; DEFRIES, R. S.; HANSEN, M. C.; LE QUÉRÉ, C.; RAMANKUTTY, N. Carbon emissions from land use and land-cover change. **Biogeosciences**, v. 9, n. 12, p. 5125–5142, 2012.

HUDAK, A. T.; CROOKSTON, N. L.; EVANS, J. S.; FALKOWSKI, M. J.; SMITH, A. M. S.; GESSLER, P. Regression modeling and mapping of coniferous forest basal area and tree density from discrete- return LiDAR and multispectral satellite data. **Canadian Journal of Remote Sensing**, v. 32, n. 2, p. 126–138, 2006.

HUDAK, A. T.; EVANS, J. S.; SMITH, A. M. S. LiDAR utility for natural resource managers. **Remote Sensing**, v. 1, n. 4, p. 934–951, 2009.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195–213, 2002.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988.

HYYPPÄ, J.; HYYPPÄ, H.; LECKIE, D.; GOUGEON, F. A.; YU, X.; MALTAMO, M. Review of methods of small - footprint airborne laser scanning for extracting forest inventory data in boreal forests. **International Journal of Remote Sensing**, v. 29, n. 5, p. 37–41, 2008.

IBGE. **Manual Técnico da Vegetação Brasileira**. Rio de Janeiro - RJ, 2012.

IBGE. **Mapa de Biomas do Brasil. Primeira aproximação. Escala 1:5.000.000**. Rio de Janeiro - RJ: IBGE, 2004.

(INPE). . **Projeto de Monitoramento do Desmatamento na Amazônia Legal - PRODES INPE**. Disponível em:

<<http://www.obt.inpe.br/prodes/dashboard/prodes-rates.html>>. Acesso em: 1 mar. 2018.

JENSEN, J. R. **Remote Sensing of the Environment: An Earth Resource Perspective**. 2. ed. Upper Saddle River, NJ: Pearson Prentice Hall, 2009.

JIN, Y.; YANG, X.; QIU, J.; LI, J.; GAO, T.; WU, Q.; ZHAO, F.; MA, H.; YU, H.;

XU, B. Remote sensing-based biomass estimation and its spatio-temporal variations in temperate Grassland, Northern China. **Remote Sensing**, v. 6, n. 2, p. 1496–1513, 2014.

JORDAN, C. F. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor Author. **Ecology**, v. 50, n. 4, p. 663–666, 1969.

JOSHI, N.; MITCHARD, E. T. A.; WOO, N.; TORRES, J.; MOLL-ROCEK, J.; EHAMMER, A.; COLLINS, M.; JEPSEN, M. R.; FENSHOLT, R. Mapping dynamics of deforestation and forest degradation in tropical forests using radar satellite data. **Environmental Research Letters**, v. 10, n. 3, 2015.

KAUFMAN, Y. J.; TANRÉ, D. Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261–270, 1992.

KAUTH, R. J.; THOMAS, G. S. The tasselled cap - A graphic description of the spectral-temporal development of agricultural crops as seen by Landsat. **Proceedings of the Symposium on Machine Processing of Remotely Sensed Data**, p. 41–51, 1976.

KERSTEN, R. DE A.; GALVÃO, F. Suficiência amostral em inventários florísticos e fitossociológicos. **Fitossociologia no Brasil: métodos e estudos de caso.**, v. 1, n. January 2011, p. 156–173, 2011.

KUMAR, V. **Forest Inventory Parameters and Carbon Mapping From Airborne LIDAR**. 2012. University of Twente. 2012.

KUNZ, S. H.; IVANAUSKAS, N. M.; MARTINS, S. V.; SILVA, E.; STEFANELLO, D. Aspectos florísticos e fitossociológicos de um trecho de Floresta Estacional Perenifólia na Fazenda Trairão, Bacia do rio das Pacas, Querência-MT. **Acta Amazonica**, v. 38, n. 2, p. 245–254, 2008.

KUTNER, M. H.; NACHTSHEIM, C.; NETER, J. **Applied linear regression models**. 4. ed. Chicago - Irwin: [S.N.], 2004.

LE QUÉRÉ, C. et al. Trends in the sources and sinks of carbon dioxide. **Nature Geoscience**, v. 2, n. 12, p. 831–836, 2009.

LEFSKY, M. A.; COHEN, W. B.; PARKER, G. G.; HARDING, D. J. Lidar Remote Sensing for Ecosystem Studies. **BioScience**, v. 52, n. 1, p. 19–30, 2002.

LIMA, A.; SILVA, T. S. F.; DE ARAGÃO, L. E. O. E. C.; DE FEITAS, R. M.; ADAMI, M.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E. Land use and land cover changes determine the spatial relationship between fire and deforestation in the Brazilian Amazon. **Applied Geography**, v. 34, p. 239–246, 2012.

LOAGUE, K.; GREEN, R. E. Statistical and graphical methods for evaluating

solute transport models: Overview and application. **Journal of Contaminant Hydrology**, v. 7, n. 1–2, p. 51–73, 1991.

LOARIE, S. R.; ASNER, G. P.; FIELD, C. B. Boosted carbon emissions from Amazon deforestation. **Geophysical Research Letters**, v. 36, n. 14, p. 1–5, 2009.

LONGO, M.; KELLER, M. M.; DOS-SANTOS, M. N.; LEITOLD, V.; PINAGÉ, E. R.; BACCINI, A.; SAATCHI, S.; NOGUEIRA, E. M.; BATISTELLA, M.; MORTON, D. C. Aboveground biomass variability across intact and degraded forests in the Brazilian Amazon. **Global Biogeochemical Cycles**, p. 1–22, 2016.

LU, D. Aboveground biomass estimation using Landsat TM data in the Brazilian Amazon. **International Journal of Remote Sensing**, v. 26, n. 12, p. 2509–2525, 2005.

LU, D.; BATISTELLA, M. Exploring TM Image Texture and its Relationships with Biomass Estimation in Rondônia , Brazilian Amazon . **Acta Amazonica**, v. 35, n. 2, p. 249–257, 2005.

LU, D.; CHEN, Q.; WANG, G.; MORAN, E.; BATISTELLA, M.; ZHANG, M.; LAURIN, G. V.; SAAH, D. Aboveground Forest Biomass Estimation with Landsat and LiDAR Data and Uncertainty Analysis of the Estimates. **International Journal of Forestry Research**, n. 1, p. 16, 2012.

MAGURRAN, A. **Ecological diversity and its measurement**. Princeton ed. Princeton, NJ, USA.: [S.N.], 1988.

MARENGO, J. A.; TOMASELLA, J.; ALVES, L. M.; SOARES, W. R.; RODRIGUEZ, D. A. The drought of 2010 in the context of historical droughts in the Amazon region. **Geophysical Research Letters**, v. 38, n. 12, p. 1–5, 2011.

MATRICARDI, E. A. T.; SKOLE, D. L.; PEDLOWSKI, M. A.; CHOMENTOWSKI, W.; FERNANDES, L. C. Assessment of tropical forest degradation by selective logging and fire using Landsat imagery. **Remote Sensing of Environment**, v. 114, n. 5, p. 1117–1129, 2010.

MAUÉS, M. M.; OLIVEIRA, P. E. A. M. Consequências da fragmentação do habitat na ecologia reprodutiva de espécies arbóreas em florestas tropicais, com ênfase na amazônia. **Oecologia Australis**, v. 14, n. 1, p. 238–250, 2010.

MCGAUGHEY, R. J. M. FUSION/LDV: Software for LIDAR Data Analysis and Visualization. United States Department of Agriculture, Forest Service, Pacific Northwest Research Station. p. 211, 2016.

MEANS, J. E.; ACKER, S. A.; FITT, B. J.; RENSLOW, M.; EMERSON, L.; ABSTRACT, C. J. H. Predicting Forest Stand Characteristics with Airborne Scanning Lidar. **Photogrammetric Engineering & Remote Sensing**, v. 66, n.

11, p. 1367–1371, 2000.

MILLER, A. J. Selection of Subsets of Regression Variables. **Journal of the Royal Statistical Society. Series A (General)**, v. 147, n. 3, p. 389, 1984.

MORAN, E. F.; BRONDIZIO, E.; MAUSEL, P.; WU, Y. Integrating Amazonian Vegetation, Land-Use, and Satellite Data. **BioScience**, v. 44, n. 5, p. 329–338, 1994.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 4. ed. Viçosa - MG: UFV, 2011.

MOREIRA, M. A.; SHIMABUKURO, Y. E. **Cálculo do Índice de Vegetação a Partir do Sensor AVHRR**. 6ª ed. São Paulo - SP: Oficina de Textos, 2004. 272 p. 4.

MORISITA, M. I  $\sigma$ -Index, a measure of dispersion of individual. **Researches on population ecology**, v. 4, n. 1, p. 1–7, 1962.

MORISITA, M. Measuring of the dispersion of individuals and analysis of the distributional patterns. **Memories of Faculty Science, Kyushu University Ser. E. Biol**, 3, v. Vol. 2, No, p. 215–235, 1959a.

(M). MORISITA. **Measuring of the dispersion of individuals and analysis of the distributional patterns**. [S.l: s.n.] . 1959b. **EXCLUIR O TIPO DE MÍDIA DO ABSTRACT OU URL!!!**

MORTON, D. C.; DEFRIES, R. S.; NAGOL, J.; SOUZA, C. M.; KASISCHKE, E. S.; HURTT, G. C.; DUBAYAH, R. Mapping canopy damage from understory fires in Amazon forests using annual time series of Landsat and MODIS data. **Remote Sensing of Environment**, v. 115, n. 7, p. 1706–1720, 2011.

MOTA, L. L.; BOTON, D.; FONSECA, R. C.; SILVA, W. C.; SOUZA, A. P. Balanço Hídrico Climatológico e Classificação Climática da Região de Sinop , Mato Grosso. **Scientific Electronic Archives**, v. 3, p. 38–44, 2013.

MUELLER-DOMBOIS, D.; ELLENBERG, D. **Aims and Methods of Vegetation Ecology**. New York, Wiley, 1974.

MYERS, N.; MITTERMEIER, R. A. R.; MITTERMEIER, C. G.; FONSECA, G. A. B.; KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853–8, 2000.

NÆSSET, E. Estimating above-ground biomass in young forests with airborne laser scanning. **International Journal of Remote Sensing**, v. 32, n. 2, p. 473–501, 2011.

NÆSSET, E.; GOBAKKEN, T. Estimation of above- and below-ground biomass across regions of the boreal forest zone using airborne laser. **Remote Sensing of Environment**, v. 112, n. 6, p. 3079–3090, 2008.

NIMER, E. Climatologia da Região Centro-Oeste do Brasil Introdução à Climatologia Dinâmica. **Revista Brasileira de Geografia**, v. 34, n. 4, p. 3–30, 1972.

NIU, Z.; XU, Z.; SUN, G.; HUANG, W.; WANG, L.; FENG, M.; LI, W.; HE, W.; GAO, S. Design of a New Multispectral Waveform LiDAR Instrument to Monitor Vegetation. **IEEE Geoscience and Remote Sensing Letters**, v. 12, n. 7, p. 1506–1510, 2015.

(JARI). OKSANEN, (F. GUILLAUME). BLANCHET, (MICHAEL). FRIENDLY, (ROELAND). KINDT, (PIERRE). LEGENDRE, (DAN). MCGLINN, (PETER R.). MINCHIN, (R. ). O'HARA, (GAVIN L.). SIMPSON, (PETER). SOLYMOS, (M. HENRY H.). STEVENS, (EDUARD). SZOECS, (HELENE). WAGNER. **vegan: Community Ecology Package**. [S.l: s.n.] . 2017. Disponível em: <<http://cran.r-project.org/package=vegan>>. Acesso em: 5 ago. 2017.

OMETTO, J. P.; AGUIAR, A. P.; ASSIS, T.; SOLER, L.; VALLE, P.; TEJADA, G.; LAPOLA, D. M.; MEIR, P. Amazon forest biomass density maps: Tackling the uncertainty in carbon emission estimates. **Climatic Change**, v. 124, n. 3, p. 545–560, 2014.

OTA, T. et al. Estimating aboveground carbon using airborne LiDAR in Cambodian tropical seasonal forests for REDD+ implementation. **Journal of Forest Research**, v. 20, n. 6, p. 484–492, 2015.

PAISAGENS SUSTENTÁVEIS. Forest Inventory : Feliz Natal and União do Sul. p. 1–3, 2015.

PAISAGENS SUSTENTÁVEIS. Forest Inventory: Fazenda Tanguro. v. 1, p. 1–4, 2012.

PAISAGENS SUSTENTÁVEIS. Forest Inventory: Feliz Natal. v. 1, p. 1–4, 2013.

PEARSON, T. R. H.; BROWN, S.; CASARIM, F. M. Carbon emissions from tropical forest degradation caused by logging. **Environmental Research Letters**, v. 9, n. 3, 2014.

PEREIRA, R.; ZWEEDE, J.; ASNER, G. P.; KELLER, M. Forest canopy damage and recovery in reduced-impact and conventional selective logging in eastern Para, Brazil. **Forest Ecology and Management**, v. 168, n. 1–3, p. 77–89, 2002.

PIELOU, E. C. The measurement of diversity in different types of biological collections. **Journal of Theoretical Biology**, v. 15, n. 1, p. 177, 1967.

PINARD, M.; HOWLETT, B.; DAVIDSON, D. Site conditions limit pioneer tree recruitment after logging of dipterocarp forests in Sabah, Malaysia. **Biotropica**, v. 28, n. 1, p. 2–12, 1996.

PINTY, B.; VERSTRAETE, M. M. GEMI: a non-linear index to monitor global vegetation from satellites. **Vegetatio**, v. 101, n. 1, p. 15–20, 1992.

PONZONI, F. J. In: MENESES, P. R.; MADEIRA NETTO, J. S. (Org.). . **Comportamento Espectral da Vegetação**. Brasília - DF: Embrapa Cerrados, 2001. 157–199 p.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2. ed. ed. São Paulo - SP: Oficina de Textos, 2012.

QUESADA, C. A. et al. Basin-wide variations in Amazon forest structure and function are mediated by both soils and climate. **Biogeosciences**, v. 9, n. 6, p. 2203–2246, 2012.

R CORE TEAM. **R: A language and environment for statistical computing**. v. 3.3.2. R Foundation for Statistical Computing, Vienna, Áustria.: Vienna, Áustria. 2016. Disponível em: <<https://www.r-project.org>>.

RAMÍREZ, F. L. B. **Modelagem de Biomassa Acima do Solo e Emissões de Carbono Associadas A Mudanças Na Cobertura da Terra na Floresta Tropical Amazônica Equatoriana**. 2015. Dissertação de Mestrado em Sensoriamento Remoto. Instituto Nacional de Pesquisas Espaciais. 2015.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95–107, 1996.

ROUJEAN, J. L.; BREON, F. M. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. **Remote Sensing of Environment**, v. 51, n. 3, p. 375–384, 1995.

ROUSE, J. W.; HASS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite (ERTS) symposium**, v. 1, p. 309–317, 1973.

SAATCHI, S.; HOUGHTON, R. A.; DOS SANTOS ALVALÁ, R. C.; SOARES, J. V.; YU, Y. Distribution of aboveground live biomass in the Amazon basin. **Global Change Biology**, v. 13, n. 4, p. 816–837, 2007.

SAATCHI, S. S.; HARRIS, N. L.; BROWN, S.; LEFSKY, M.; MITCHARD, E. T. A.; SALASF, W.; ZUTTAA, B. R.; BUERMANN, W.; LEWIS, S. L.; HAGEN, S.; PETROVIC, S.; WHITEH, L.; SILMANI, M.; MORELJ, A. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the National Academy of Sciences**, v. 108, n. 24, p. 9899–9904, 2011.

SARKER, L. R.; NICHOL, J. E. Improved forest biomass estimates using ALOS AVNIR-2 texture indices. **Remote Sensing of Environment**, v. 115, n. 4, p. 968–977, 2011.

- SARKER, M. L. R.; NICHOL, J.; IZ, H. B.; AHMAD, B. BIN; RAHMAN, A. A. Forest biomass estimation using texture measurements of high-resolution dual-polarization C-band SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 6, p. 3371–3384, 2013.
- SATO, L.; GOMES, V.; SHIMABUKURO, Y.; KELLER, M.; ARAI, E.; DOS-SANTOS, M.; BROWN, I.; ARAGÃO, L. Post-Fire Changes in Forest Biomass Retrieved by Airborne LiDAR in Amazonia. **Remote Sensing**, v. 8, n. 10, p. 839, 2016.
- SHANNON, C. E.; WEAVER, W. The Mathematical Theory of Communication. **The mathematical theory of communication**, v. 27, n. 4, p. 117, 1949.
- SHIMABUKURO, Y. E.; ARAI, E.; SANTOS, E. G.; JORGE, A. Monitoring Deforestation and Forest Degradation using Multi-Temporal Fractions Images Derived from Landsat Sensor Data in the Brazilian Amazon. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 165–168, 2017.
- SHIMABUKURO, Y. E.; BEUCHLE, R.; GRECCHI, R. C.; ACHARD, F. Assessment of forest degradation in Brazilian Amazon due to selective logging and fires using time series of fraction images derived from Landsat ETM+ images. **Remote Sensing Letters**, v. 5, n. 9, p. 773–782, 2014.
- SHIMABUKURO, Y. E.; SMITH, J. A. The Least-Squares Mixing Models to Generate Fraction Images Derived From Remote Sensing Multispectral Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 1, p. 16–20, 1991.
- SILGUEIRO, V.; THUAULT, A.; MICOL, L.; ABAD, R. Mapeamento da ilegalidade na exploração madeireira entre agosto de 2012 e julho de 2013. **Transparência Florestal Mato Grosso**, v. 5, n. 4, p. 12, 2015.
- SILVA, C. A.; HUDAK, A. T.; VIERLING, L. A.; KLAUBERG, C.; GARCIA, M.; FERRAZ, A.; KELLER, M.; EITEL, J.; SAATCHI, S. Impacts of airborne lidar pulse density on estimating biomass stocks and changes in a selectively logged tropical forest. **Remote Sensing**, v. 9, n. 10, 2017.
- SONG, X. P.; HUANG, C.; SAATCHI, S. S.; HANSEN, M. C.; TOWNSHEND, J. R. Annual carbon emissions from deforestation in the Amazon basin between 2000 and 2010. **PLoS ONE**, v. 10, n. 5, p. 1–21, 2015.
- SOUZA, D. R. DE; SOUZA, A. L. DE; LEITE, H. G.; YARED, J. A. G. Análise estrutural em Floresta Ombrófila Densa de Terra Firme não explorada, Amazônia Oriental. **Revista Árvore**, v. 30, n. 1, p. 75–87, 2005.
- STEPHENS, P. R.; KIMBERLEY, M. O.; BEETS, P. N.; PAUL, T. S. H.; SEARLES, N.; BELL, A.; BRACK, C.; BROADLEY, J. Airborne scanning LiDAR in a double sampling forest carbon inventory. **Remote Sensing of Environment**, v. 117, p. 348–357, 2012.

- SUN, G.; RANSON, K. J.; KIMES, D. S.; BLAIR, J. B.; KOVACS, K. Forest vertical structure from GLAS: An evaluation using LVIS and SRTM data. **Remote Sensing of Environment**, v. 112, n. 1, p. 107–117, 2008.
- TREUHAFT, R. N.; CHAPMAN, B. D.; DOS SANTOS, J. R.; GONÇALVES, F. G.; DUTRA, L. V.; GRAÇA, P. M. L. A.; DRAKE, J. B. Vegetation profiles in tropical forests from multibaseline interferometric synthetic aperture radar, field, and lidar measurements. **Journal of Geophysical Research Atmospheres**, v. 114, n. 23, p. 1–16, 2009.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.
- UNSER, M. Sum and Difference Histograms for Texture Classification. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. PAMI-8, n. 1, p. 118–125, 1986.
- VASCONCELOS, S. S. DE; FEARNSSIDE, P. M.; GRAÇA, P. M. L. DE A.; NOGUEIRA, E. M.; OLIVEIRA, L. C. DE; FIGUEIREDO, E. O. Forest fires in southwestern Brazilian Amazonia: Estimates of area and potential carbon emissions. **Forest Ecology and Management**, v. 291, p. 199–208, 2013.
- WEISBIN, C. R.; LINCOLN, W.; SAATCHI, S. Model Based Systems Engineering with Department of Defense Architectural Framework. **Systems Engineering**, v. 14, n. 3, p. 305–326, 2011.
- WULDER, M. A.; WHITE, J. C.; NELSON, R. F.; NÆSSET, E.; ØRKA, H. O.; COOPS, N. C.; HILKER, T.; BATER, C. W.; GOBAKKEN, T. Lidar sampling for large-area forest characterization: A review. **Remote Sensing of Environment**, v. 121, p. 196–209, 2012.
- YANG, Z.; WILLIS, P.; MUELLER, R. Impact of Band-Ratio Enhanced Awifs Image To Crop Classification Accuracy. p. 11, 2008.
- YOUNG, N. E.; ANDERSON, R. S.; CHIGNELL, S. M.; VORSTER, A. G.; LAWRENCE, R.; EVANGELISTA, P. H. A survival guide to Landsat preprocessing. **Ecology**, v. 98, n. 4, p. 920–932, 2017.
- ZANNE, A. E.; LOPEZ-GONZALEZ, G.; COOMES, D. A.; ILIC, J.; JANSEN, S.; LEWIS, S. L.; MILLER, R. B.; SWENSON, N. G.; WIEMANN, M. C.; CHAVE, J. Global wood density database. v. Dryad. Ide, 2009.
- ZHURAVLEVA, I.; TURUBANOVA, S.; POTAPOV, P.; HANSEN, M.; TYUKAVINA, A.; MINNEMEYER, S.; LAPORTE, N.; GOETZ, S.; VERBELEN, F.; THIES, C. Satellite-based primary forest degradation assessment in the Democratic Republic of the Congo, 2000-2010. **Environmental Research Letters**, v. 8, n. 2, 2013.



**APÊNDICE A – TABELA COM OS DESCRITORES FITOSSOCIOLÓGICOS  
COM TODAS AS ESPÉCIES MENSURADAS A CAMPO**

**A.1 Tabela**

Tabela A.1 - Descritores fitossociológicos para todas as espécies presente em campo.

<b>Espécie</b>	<b>N</b>	<b>DA</b>	<b>DR</b>	<b>DoA</b>	<b>DoR</b>	<b>FA</b>	<b>FR</b>	<b>VI</b>
<i>Morta Não Ident.</i>	491	17,38	11,52	1,38	15,11	86,73	5,93	10,85
<i>Protium sagotianum</i>	434	15,36	10,18	0,3	3,25	15,04	1,03	4,82
<i>Qualea paraensis</i>	155	5,49	3,64	0,63	6,88	28,32	1,94	4,15
<i>Protium heptaphyllum</i>	114	4,04	2,67	0,56	6,11	30,09	2,06	3,61
<i>Endlicheria ruforamula</i>	76	2,69	1,78	0,18	1,98	30,09	2,06	1,94
<i>Ocotea matogrossensis</i>	123	4,35	2,89	0,16	1,71	14,16	0,97	1,86
<i>Manilkara huberi</i>	49	1,73	1,15	0,23	2,56	23,89	1,63	1,78
<i>Jacaranda copaia</i>	85	3,01	1,99	0,11	1,21	29,2	2	1,73
<i>Trattinnickia rhoifolia</i>	91	3,22	2,14	0,2	2,14	13,27	0,91	1,73
<i>Sacoglottis guianensis</i>	67	2,37	1,57	0,15	1,61	25,66	1,75	1,65
<i>Licania octandra</i>	64	2,27	1,5	0,17	1,83	23,01	1,57	1,63
<i>Bertholletia excelsa</i>	10	0,35	0,23	0,36	3,99	6,19	0,42	1,55
<i>Miconia poeppigii</i>	100	3,54	2,35	0,09	0,96	15,93	1,09	1,46
<i>Tetragastris altissima</i>	37	1,31	0,87	0,17	1,83	18,58	1,27	1,32
<i>Inga alba</i>	68	2,41	1,6	0,08	0,82	18,58	1,27	1,23
<i>Goupia glabra</i>	29	1,03	0,68	0,15	1,6	15,04	1,03	1,1
<i>Aspidosperma excelsum</i>	21	0,74	0,49	0,17	1,86	13,27	0,91	1,09
<i>Casearia javitensis</i>	46	1,63	1,08	0,03	0,31	26,55	1,81	1,07
<i>Sloanea guianensis</i>	47	1,66	1,1	0,03	0,38	24,78	1,69	1,06
<i>Maquira guianensis</i>	62	2,19	1,45	0,07	0,74	13,27	0,91	1,03
<i>Xylopia sp.</i>	46	1,63	1,08	0,05	0,59	20,35	1,39	1,02
<i>Dialium guianense</i>	41	1,45	0,96	0,1	1,05	15,04	1,03	1,01
<i>Dipteryx odorata</i>	21	0,74	0,49	0,13	1,38	15,93	1,09	0,99
<i>Pseudolmedia laevis</i>	52	1,84	1,22	0,11	1,19	7,96	0,54	0,98
<i>Pouteria gongrijpii</i>	32	1,13	0,75	0,1	1,1	15,93	1,09	0,98
<i>Myrcia velutina</i>	43	1,52	1,01	0,03	0,34	23,01	1,57	0,97
<i>Vochysia guianensis</i>	31	1,1	0,73	0,08	0,84	19,47	1,33	0,97
<i>Trattinnickia burserifolia</i>	32	1,13	0,75	0,09	0,99	15,93	1,09	0,94
<i>Tapirira guianensis</i>	30	1,06	0,7	0,06	0,65	21,24	1,45	0,94
<i>Ormosia excelsa</i>	14	0,5	0,33	0,16	1,79	9,73	0,67	0,93
<i>Aspidosperma nitidum</i>	20	0,71	0,47	0,13	1,38	13,27	0,91	0,92
<i>Schefflera morototoni</i>	33	1,17	0,77	0,07	0,75	17,7	1,21	0,91
<i>Aparisthmium cordatum</i>	65	2,3	1,53	0,03	0,34	12,39	0,85	0,9
<i>Micropholis guyanensis</i>	46	1,63	1,08	0,08	0,82	11,5	0,79	0,9

(Continua)

Tabela A.1 - Continuação

<b>Espécie</b>	<b>N</b>	<b>DA</b>	<b>DR</b>	<b>DoA</b>	<b>DoR</b>	<b>FA</b>	<b>FR</b>	<b>VI</b>
<i>Erismia bicolor</i>	48	1,7	1,13	0,05	0,6	13,27	0,91	0,88
<i>Pouteria sp.</i>	25	0,88	0,59	0,07	0,78	17,7	1,21	0,86
<i>Bellucia grossularioides</i>	54	1,91	1,27	0,04	0,47	12,39	0,85	0,86
<i>Erismia uncinatum</i>	19	0,67	0,45	0,13	1,42	8,85	0,6	0,83
<i>Tovomita grata</i>	52	1,84	1,22	0,04	0,41	10,62	0,73	0,79
<i>Matayba macrostylis</i>	47	1,66	1,1	0,03	0,34	13,27	0,91	0,78
<i>Aniba parviflora</i>	16	0,57	0,38	0,09	0,95	12,39	0,85	0,73
<i>Mezilaurus itauba</i>	16	0,57	0,38	0,1	1,05	9,73	0,67	0,7
<i>Cheiloclinium cognatum</i>	44	1,56	1,03	0,02	0,26	11,5	0,79	0,69
<i>Aspidosperma desmanthum</i>	23	0,81	0,54	0,06	0,69	8,85	0,6	0,61
<i>Apeiba echinata</i>	27	0,96	0,63	0,07	0,71	7,08	0,48	0,61
<i>Nectandra cuspidata</i>	19	0,67	0,45	0,03	0,33	15,04	1,03	0,6
<i>Amaioua guianensis</i>	32	1,13	0,75	0,02	0,26	10,62	0,73	0,58
<i>Heisteria densifrons</i>	24	0,85	0,56	0,01	0,13	15,04	1,03	0,58
<i>Esenbeckia febrifuga</i>	30	1,06	0,7	0,02	0,26	9,73	0,67	0,54
<i>Strychnos subcordata</i>	21	0,74	0,49	0,01	0,12	14,16	0,97	0,53
<i>Protium paniculatum</i>	23	0,81	0,54	0,02	0,17	12,39	0,85	0,52
<i>Bocageopsis pleiosperma</i>	20	0,71	0,47	0,02	0,18	13,27	0,91	0,52
<i>Cecropia sciadophylla</i>	32	1,13	0,75	0,05	0,51	3,54	0,24	0,5
<i>Cordia scabrifolia</i>	14	0,5	0,33	0,04	0,49	9,73	0,67	0,49
<i>Mabea fistulifera</i>	21	0,74	0,49	0,03	0,37	8,85	0,6	0,49
<i>Apuleia leiocarpa</i>	9	0,32	0,21	0,08	0,83	6,19	0,42	0,49
<i>Nectandra lanceolata</i>	21	0,74	0,49	0,04	0,4	7,96	0,54	0,48
<i>Chrysophyllum sanguinolentum</i>	23	0,81	0,54	0,05	0,51	5,31	0,36	0,47
<i>Copaifera reticulata</i>	12	0,42	0,28	0,05	0,57	7,96	0,54	0,46
<i>Tachigali setifera</i>	27	0,96	0,63	0,03	0,38	5,31	0,36	0,46
<i>Hirtella racemosa</i>	19	0,67	0,45	0,04	0,38	7,96	0,54	0,46
<i>Astrocaryum aculeatum</i>	17	0,6	0,4	0,02	0,25	10,62	0,73	0,46
<i>Pouteria guianensis</i>	21	0,74	0,49	0,05	0,51	4,42	0,3	0,44
<i>Mucuna rostrata</i>	18	0,64	0,42	0,01	0,13	10,62	0,73	0,43
<i>Terminalia amazonia</i>	9	0,32	0,21	0,06	0,62	6,19	0,42	0,42
<i>Metrodorea flavida</i>	22	0,78	0,52	0,03	0,28	6,19	0,42	0,41
<i>Dussia tessmannii</i>	7	0,25	0,16	0,06	0,63	6,19	0,42	0,4
<i>Tachigali venusta</i>	18	0,64	0,42	0,03	0,35	6,19	0,42	0,4
<i>Guatteria olivacea</i>	28	0,99	0,66	0,02	0,18	5,31	0,36	0,4
<i>Xylopia parviflora</i>	18	0,64	0,42	0,02	0,26	7,08	0,48	0,39
<i>Miconia ferruginea</i>	19	0,67	0,45	0,01	0,11	8,85	0,6	0,39
<i>Ocotea nigrescens</i>	19	0,67	0,45	0,02	0,26	6,19	0,42	0,38

(Continua)

Tabela A.1 - Continuação

<b>Espécie</b>	<b>N</b>	<b>DA</b>	<b>DR</b>	<b>DoA</b>	<b>DoR</b>	<b>FA</b>	<b>FR</b>	<b>VI</b>
<i>Guatteria schomburgkiana</i>	14	0,5	0,33	0,01	0,09	9,73	0,67	0,36
<i>Cecropia distachya</i>	17	0,6	0,4	0,02	0,19	7,08	0,48	0,36
<i>Mouriri collocarpa</i>	11	0,39	0,26	0,02	0,21	8,85	0,6	0,36
<i>Byrsonima crispa</i>	12	0,42	0,28	0,02	0,23	7,96	0,54	0,35
<i>Inga cordatoalata</i>	18	0,64	0,42	0,01	0,11	7,08	0,48	0,34
<i>Himatanthus sucuuba</i>	7	0,25	0,16	0,04	0,43	6,19	0,42	0,34
<i>Pseudolmedia laevigata</i>	15	0,53	0,35	0,03	0,27	5,31	0,36	0,33
<i>Endlicheria sp.</i>	9	0,32	0,21	0,03	0,28	7,08	0,48	0,33
<i>Licania micrantha</i>	15	0,53	0,35	0,02	0,25	5,31	0,36	0,32
<i>Albizia pedicellaris</i>	7	0,25	0,16	0,04	0,43	5,31	0,36	0,32
<i>Mouriri nervosa</i>	18	0,64	0,42	0,01	0,16	5,31	0,36	0,32
<i>Neea oppositifolia</i>	9	0,32	0,21	0,02	0,23	7,08	0,48	0,31
<i>Tachigali vulgaris</i>	14	0,5	0,33	0,03	0,34	3,54	0,24	0,3
<i>Enterolobium schomburgkii</i>	6	0,21	0,14	0,04	0,4	5,31	0,36	0,3
<i>Neea ovalifolia</i>	13	0,46	0,31	0,01	0,15	6,19	0,42	0,29
<i>Stryphnodendron racemiferum</i>	10	0,35	0,23	0,02	0,27	5,31	0,36	0,29
<i>Laetia procera</i>	9	0,32	0,21	0,02	0,27	5,31	0,36	0,28
<i>Caryocar villosum</i>	2	0,07	0,05	0,06	0,66	1,77	0,12	0,28
<i>Faramea capillipes</i>	13	0,46	0,31	0,01	0,07	6,19	0,42	0,27
<i>Helicostylis scabra</i>	14	0,5	0,33	0,02	0,17	4,42	0,3	0,27
<i>Miconia affinis</i>	13	0,46	0,31	0	0,05	6,19	0,42	0,26
<i>Swartzia arborescens</i>	16	0,57	0,38	0,01	0,09	4,42	0,3	0,26
<i>Sloanea nitida</i>	9	0,32	0,21	0,01	0,07	7,08	0,48	0,25
<i>Dimorphandra pennigera</i>	12	0,42	0,28	0,01	0,09	5,31	0,36	0,24
<i>Tachigali paniculata</i>	6	0,21	0,14	0,03	0,29	4,42	0,3	0,24
<i>Miconia cuspidata</i>	9	0,32	0,21	0,01	0,09	6,19	0,42	0,24
<i>Hirtella sp.</i>	8	0,28	0,19	0,03	0,29	3,54	0,24	0,24
<i>Parkia pendula</i>	5	0,18	0,12	0,03	0,3	4,42	0,3	0,24
<i>Aspidosperma spruceanum</i>	7	0,25	0,16	0,01	0,13	6,19	0,42	0,24
<i>Casearia grandiflora</i>	11	0,39	0,26	0,01	0,07	5,31	0,36	0,23
<i>Vochysia maxima</i>	7	0,25	0,16	0,02	0,17	5,31	0,36	0,23
<i>Tachigali glauca</i>	9	0,32	0,21	0,02	0,24	3,54	0,24	0,23
<i>Ocotea cernua</i>	7	0,25	0,16	0,01	0,09	6,19	0,42	0,23
<i>Sorocea guilleminiana</i>	7	0,25	0,16	0,01	0,07	6,19	0,42	0,22
<i>Ocotea sp.</i>	7	0,25	0,16	0,01	0,1	5,31	0,36	0,21
<i>Helicostylis sp.</i>	6	0,21	0,14	0,01	0,12	5,31	0,36	0,21
<i>Hymenolobium modestum</i>	7	0,25	0,16	0,02	0,2	3,54	0,24	0,2
<i>Inga sp.</i>	8	0,28	0,19	0	0,05	5,31	0,36	0,2
<i>Ormosia coccinea</i>	6	0,21	0,14	0,01	0,07	5,31	0,36	0,19

(Continua)

Tabela A.1 - Continuação

<b>Espécie</b>	<b>N</b>	<b>DA</b>	<b>DR</b>	<b>DoA</b>	<b>DoR</b>	<b>FA</b>	<b>FR</b>	<b>VI</b>
<i>Inga obidensis</i>	5	0,18	0,12	0,02	0,2	3,54	0,24	0,19
<i>Ormosia grossa</i>	7	0,25	0,16	0,01	0,07	4,42	0,3	0,18
<i>Hymenolobium petraeum</i>	3	0,11	0,07	0,03	0,28	2,65	0,18	0,18
<i>Mollia lepidota</i>	6	0,21	0,14	0,01	0,07	4,42	0,3	0,17
<i>Pouteria reticulata</i>	6	0,21	0,14	0,01	0,07	4,42	0,3	0,17
<i>Eriotheca globosa</i>	5	0,18	0,12	0,01	0,09	4,42	0,3	0,17
<i>Mouriri nigra</i>	7	0,25	0,16	0,01	0,09	3,54	0,24	0,17
<i>Cecropia palmata</i>	5	0,18	0,12	0,01	0,07	4,42	0,3	0,16
<i>Bowdichia nitida</i>	4	0,14	0,09	0,01	0,14	3,54	0,24	0,16
<i>Alchornea discolor</i>	7	0,25	0,16	0,01	0,06	3,54	0,24	0,16
<i>Eschweilera carinata</i>	7	0,25	0,16	0,01	0,06	3,54	0,24	0,16
<i>Calophyllum brasiliense</i>	5	0,18	0,12	0	0,05	3,54	0,24	0,14
<i>Bocageopsis multiflora</i>	5	0,18	0,12	0	0,04	3,54	0,24	0,13
<i>Maquira coriacea</i>	4	0,14	0,09	0,01	0,12	2,65	0,18	0,13
<i>Astronium lecointei</i>	5	0,18	0,12	0,01	0,06	2,65	0,18	0,12
<i>Simarouba amara</i>	3	0,11	0,07	0,01	0,11	2,65	0,18	0,12
<i>Rinoreaocarpus ulei</i>	5	0,18	0,12	0	0,05	2,65	0,18	0,12
<i>Protium sp.</i>	3	0,11	0,07	0,01	0,1	2,65	0,18	0,12
<i>Sloanea rufa</i>	5	0,18	0,12	0	0,04	2,65	0,18	0,11
<i>Tetragastris panamensis</i>	3	0,11	0,07	0,01	0,09	2,65	0,18	0,11
<i>Elaeoluma nuda</i>	5	0,18	0,12	0,02	0,16	0,88	0,06	0,11
<i>Poeppigia procera</i>	3	0,11	0,07	0,01	0,09	2,65	0,18	0,11
<i>Aspidosperma macrocarpon</i>	4	0,14	0,09	0,01	0,06	2,65	0,18	0,11
<i>Mabea angularis</i>	6	0,21	0,14	0,01	0,12	0,88	0,06	0,11
<i>Brosimum lactescens</i>	3	0,11	0,07	0,01	0,12	1,77	0,12	0,1
<i>Ampelocera edentula</i>	3	0,11	0,07	0,01	0,06	2,65	0,18	0,1
<i>Xylopia amazonica</i>	3	0,11	0,07	0	0,05	2,65	0,18	0,1
<i>Mouriri trunciflora</i>	4	0,14	0,09	0	0,02	2,65	0,18	0,1
<i>Virola melinoni</i>	4	0,14	0,09	0	0,02	2,65	0,18	0,1
<i>Emmotum nitens</i>	4	0,14	0,09	0	0,02	2,65	0,18	0,1
<i>Poeppigia sp.</i>	3	0,11	0,07	0	0,04	2,65	0,18	0,1
<i>Xylopia nitida</i>	3	0,11	0,07	0	0,02	2,65	0,18	0,09
<i>Zanthoxylum rhoifolium</i>	3	0,11	0,07	0	0,02	2,65	0,18	0,09
<i>Myrciaria floribunda</i>	3	0,11	0,07	0	0,02	2,65	0,18	0,09
<i>Copaifera langsdorffii</i>	1	0,04	0,02	0,02	0,18	0,88	0,06	0,09
<i>Buchenavia parvifolia</i>	3	0,11	0,07	0,01	0,05	1,77	0,12	0,08
<i>Hymenaea courbaril</i>	1	0,04	0,02	0,01	0,15	0,88	0,06	0,08
<i>Licania canescens</i>	2	0,07	0,05	0,01	0,07	1,77	0,12	0,08
<i>Hevea brasiliensis</i>	1	0,04	0,02	0,01	0,15	0,88	0,06	0,08

(Continua)

Tabela A.1 - Continuação

<b>Espécie</b>	<b>N</b>	<b>DA</b>	<b>DR</b>	<b>DoA</b>	<b>DoR</b>	<b>FA</b>	<b>FR</b>	<b>VI</b>
<i>Clarisia racemosa</i>	3	0,11	0,07	0	0,04	1,77	0,12	0,08
<i>Trichilia cipo</i>	3	0,11	0,07	0	0,04	1,77	0,12	0,08
<i>Tovomita sp.</i>	3	0,11	0,07	0	0,04	1,77	0,12	0,08
<i>Maquira sclerophylla</i>	3	0,11	0,07	0	0,03	1,77	0,12	0,07
<i>Tachigali myrmecophila</i>	2	0,07	0,05	0	0,05	1,77	0,12	0,07
<i>Aspidosperma parvifolium</i>	1	0,04	0,02	0,01	0,13	0,88	0,06	0,07
<i>Sweetia fruticosa</i>	3	0,11	0,07	0	0,03	1,77	0,12	0,07
<i>Diploctropis sp.</i>	3	0,11	0,07	0	0,02	1,77	0,12	0,07
<i>Micropholis cylindrocarpa</i>	3	0,11	0,07	0	0,02	1,77	0,12	0,07
<i>Erythroxyllum mucronatum</i>	3	0,11	0,07	0	0,02	1,77	0,12	0,07
<i>Siparuna guianensis</i>	3	0,11	0,07	0	0,01	1,77	0,12	0,07
<i>Licania heteromorpha</i>	2	0,07	0,05	0	0,04	1,77	0,12	0,07
<i>Diospyros guianensis</i>	2	0,07	0,05	0	0,04	1,77	0,12	0,07
<i>Cupania scrobiculata</i>	3	0,11	0,07	0	0,01	1,77	0,12	0,07
<i>Myrcia paivae</i>	2	0,07	0,05	0	0,03	1,77	0,12	0,07
<i>Heistera sp.</i>	2	0,07	0,05	0	0,03	1,77	0,12	0,06
<i>Caryocar brasiliense</i>	2	0,07	0,05	0	0,02	1,77	0,12	0,06
<i>Vochysia ferruginea</i>	2	0,07	0,05	0	0,02	1,77	0,12	0,06
<i>Toulicia sp.</i>	2	0,07	0,05	0	0,02	1,77	0,12	0,06
<i>Annona ambota</i>	2	0,07	0,05	0	0,02	1,77	0,12	0,06
<i>Licania sp.</i>	2	0,07	0,05	0	0,02	1,77	0,12	0,06
<i>Pourouma minor</i>	2	0,07	0,05	0	0,01	1,77	0,12	0,06
<i>Tapura amazonica</i>	2	0,07	0,05	0	0,01	1,77	0,12	0,06
<i>Sacoglottis mattogrossensis</i>	2	0,07	0,05	0	0,01	1,77	0,12	0,06
<i>Zanthoxylum djalmbatistae</i>	2	0,07	0,05	0	0,01	1,77	0,12	0,06
<i>Micropholis venulosa</i>	2	0,07	0,05	0	0,01	1,77	0,12	0,06
<i>Byrsonima chrysophylla</i>	2	0,07	0,05	0	0,01	1,77	0,12	0,06
<i>Inga thibaudiana</i>	2	0,07	0,05	0	0,01	1,77	0,12	0,06
<i>Ficus sp.</i>	1	0,04	0,02	0,01	0,09	0,88	0,06	0,06
<i>Guatteria anthracina</i>	4	0,14	0,09	0	0,02	0,88	0,06	0,06
<i>Iryanthera laevis</i>	2	0,07	0,05	0,01	0,06	0,88	0,06	0,05
<i>Luehea speciosa</i>	1	0,04	0,02	0,01	0,08	0,88	0,06	0,05
<i>Parkia sp.</i>	1	0,04	0,02	0,01	0,08	0,88	0,06	0,05
<i>Iryanthera ulei</i>	2	0,07	0,05	0	0,04	0,88	0,06	0,05
<i>Sterigmaphetalum obovatum</i>	2	0,07	0,05	0	0,03	0,88	0,06	0,04
<i>Thyrsodium spruceanum</i>	1	0,04	0,02	0	0,05	0,88	0,06	0,04
<i>Stryphnodendron guianense</i>	1	0,04	0,02	0	0,04	0,88	0,06	0,04

(Continua)

Tabela A.1 - Conclusão

<b>Espécie</b>	<b>N</b>	<b>DA</b>	<b>DR</b>	<b>DoA</b>	<b>DoR</b>	<b>FA</b>	<b>FR</b>	<b>VI</b>
<i>Ouratea discophora</i>	2	0,07	0,05	0	0,02	0,88	0,06	0,04
<i>Anacardium spruceanum</i>	1	0,04	0,02	0	0,04	0,88	0,06	0,04
<i>Aniba sp.</i>	2	0,07	0,05	0	0,02	0,88	0,06	0,04
<i>Aspidosperma polyneuron</i>	1	0,04	0,02	0	0,04	0,88	0,06	0,04
<i>Ormosia sp.</i>	2	0,07	0,05	0	0,01	0,88	0,06	0,04
<i>Ormosia nobilis</i>	1	0,04	0,02	0	0,04	0,88	0,06	0,04
<i>Bixa orellana</i>	2	0,07	0,05	0	0,01	0,88	0,06	0,04
<i>Croton urucurana</i>	2	0,07	0,05	0	0,01	0,88	0,06	0,04
<i>Fusaea longifolia</i>	1	0,04	0,02	0	0,02	0,88	0,06	0,04
<i>Myrcia deflexa</i>	1	0,04	0,02	0	0,02	0,88	0,06	0,04
<i>Vitex polygama</i>	1	0,04	0,02	0	0,02	0,88	0,06	0,03
<i>Sloanea synandra</i>	1	0,04	0,02	0	0,02	0,88	0,06	0,03
<i>Cecropia ficifolia</i>	1	0,04	0,02	0	0,02	0,88	0,06	0,03
<i>Helicostylis tomentosa</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Licania poeppigii</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Alibertia edulis</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Guarea guidonia</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Virola sebifera</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Myrcia pinifolia</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Myrcia fenestrata</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Virola michelii</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Oenocarpus distichus</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Swartzia laevicarpa</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Ocotea caudata</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Oenocarpus bacaba</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Miconia surinamensis</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Guatteria megalophylla</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Quiina florida</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Eugenia puniceifolia</i>	1	0,04	0,02	0	0,01	0,88	0,06	0,03
<i>Vismia guianensis</i>	1	0,04	0,02	0	0	0,88	0,06	0,03
<i>Stryphnodendron pulcherrimum</i>	1	0,04	0,02	0	0	0,88	0,06	0,03
<i>Cordia goeldiana</i>	1	0,04	0,02	0	0	0,88	0,06	0,03
<i>Cochlospermum vitifolium</i>	1	0,04	0,02	0	0	0,88	0,06	0,03
<i>Mayna odorata</i>	1	0,04	0,02	0	0	0,88	0,06	0,03
<i>Miconia sp.</i>	1	0,04	0,02	0	0	0,88	0,06	0,03
<i>Inga suberosa</i>	1	0,04	0,02	0	0	0,88	0,06	0,03

Fonte: Produzido pelo autor.

Tabela A.2 - Índice de Morisita e tipo de distribuição para cada espécie.

Espécie	IMN	Distribuição	Espécie	IMN	Distribuição
<i>Albizia pedicellaris</i>	0,42	Aleatória	<i>Maquira guianensis</i>	0,53	Agregada
<i>Alchornea discolor</i>	0,57	Agregada	<i>Maquira sclerophylla</i>	0,61	Agregada
<i>Amaioua guianensis</i>	0,56	Agregada	<i>Matayba macrostylis</i>	0,53	Agregada
<i>Ampelocera edentula</i>	-0,04	Aleatória	<i>Metrodorea flavida</i>	0,56	Agregada
<i>Aniba parviflora</i>	0,21	Aleatória	<i>Mezilaurus itauba</i>	0,53	Agregada
<i>Aniba sp</i>	1,00	Agregada	<i>Miconia affinis</i>	0,54	Agregada
<i>Annona ambota</i>	-0,02	Aleatória	<i>Miconia cuspidata</i>	0,52	Agregada
<i>Aparisthium cordatum</i>	0,53	Agregada	<i>Miconia ferruginea</i>	0,54	Agregada
<i>Apeiba echinata</i>	0,56	Agregada	<i>Miconia poeppigii</i>	0,52	Agregada
<i>Apuleia leiocarpa</i>	0,52	Agregada	<i>Micropholis cylindrocarpa</i>	0,61	Agregada
<i>Aspidosperma desmanthum</i>	0,53	Agregada	<i>Micropholis guyanensis</i>	0,54	Agregada
<i>Aspidosperma excelsum</i>	0,51	Agregada	<i>Micropholis venulosa</i>	-0,02	Aleatória
<i>Aspidosperma macrocarpon</i>	0,54	Agregada	<i>Mollia lepidota</i>	0,50	Agregada
<i>Aspidosperma nitidum</i>	0,50	Agregada	Morta Não Ident	0,50	Agregada
<i>Aspidosperma spruceanum</i>	-0,11	Aleatória	<i>Mouriri collocarpa</i>	0,17	Aleatória
<i>Astrocaryum aculeatum</i>	0,52	Agregada	<i>Mouriri nervosa</i>	0,55	Agregada
<i>Astronium lecointei</i>	0,62	Agregada	<i>Mouriri nigra</i>	0,62	Agregada
<i>Bellucia grossularioides</i>	0,62	Agregada	<i>Mouriri trunciflora</i>	0,54	Agregada
<i>Bertholletia excelsa</i>	0,53	Agregada	<i>Mucuna rostrata</i>	0,51	Agregada
<i>Bixa orellana</i>	1,00	Agregada	<i>Myrcia paivae</i>	-0,02	Aleatória
<i>Bocageopsis multiflora</i>	0,51	Agregada	<i>Myrcia velutina</i>	0,51	Agregada
<i>Bocageopsis pleiosperma</i>	0,51	Agregada	<i>Myrciaria floribunda</i>	-0,04	Aleatória
<i>Bowdichia nitida</i>	-0,05	Aleatória	<i>Nectandra cuspidata</i>	0,09	Aleatória
<i>Brosimum lactescens</i>	0,61	Agregada	<i>Nectandra lanceolata</i>	0,54	Agregada
<i>Buchenavia parvifolia</i>	0,61	Agregada	<i>Neea oppositifolia</i>	0,27	Aleatória
<i>Byrsonima chrysophylla</i>	-0,02	Aleatória	<i>Neea ovalifolia</i>	0,62	Agregada
<i>Byrsonima crispa</i>	0,51	Agregada	<i>Ocotea cernua</i>	-0,11	Aleatória
<i>Calophyllum brasiliense</i>	0,51	Agregada	<i>Ocotea matogrossensis</i>	0,55	Agregada
<i>Caryocar brasiliense</i>	-0,02	Aleatória	<i>Ocotea nigrescens</i>	0,59	Agregada
<i>Caryocar villosum</i>	-0,02	Aleatória	<i>Ocotea sp</i>	0,42	Aleatória
<i>Casearia grandiflora</i>	0,58	Agregada	<i>Ormosia coccinea</i>	-0,09	Aleatória
<i>Casearia javitensis</i>	0,50	Agregada	<i>Ormosia excelsa</i>	0,50	Agregada
<i>Cecropia distachya</i>	0,56	Agregada	<i>Ormosia grossa</i>	0,52	Agregada
<i>Cecropia palmata</i>	-0,07	Aleatória	<i>Ormosia sp</i>	1,00	Agregada
<i>Cecropia sciadophylla</i>	0,68	Agregada	<i>Ouratea discophora</i>	1,00	Agregada
<i>Cheiloclinium cognatum</i>	0,53	Agregada	<i>Parkia pendula</i>	-0,07	Aleatória
<i>Chrysophyllum sanguinolentum</i>	0,58	Agregada	<i>Poeppigia procera</i>	-0,04	Aleatória
<i>Clarisia racemosa</i>	0,61	Agregada	<i>Poeppigia sp</i>	-0,04	Aleatória
<i>Copaifera reticulata</i>	0,51	Agregada	<i>Pourouma minor</i>	-0,02	Aleatória

(Continua)

Tabela A.2 - Continuação

<b>Espécie</b>	<b>IMN</b>	<b>Distribuição</b>	<b>Espécie</b>	<b>IMN</b>	<b>Distribuição</b>
<i>Cordia scabrifolia</i>	0,51	Agregada	<i>Pouteria gongrijpii</i>	0,51	Agregada
<i>Croton urucurana</i>	1,00	Agregada	<i>Pouteria guianensis</i>	0,60	Agregada
<i>Cupania scrobiculata</i>	0,61	Agregada	<i>Pouteria reticulata</i>	0,50	Agregada
<i>Dialium guianense</i>	0,52	Agregada	<i>Pouteria sp</i>	0,34	Aleatória
<i>Dimorphandra pennigera</i>	0,61	Agregada	<i>Protium heptaphyllum</i>	0,51	Agregada
<i>Diospyros guianensis</i>	-0,02	Aleatória	<i>Protium paniculatum</i>	0,51	Agregada
<i>Diptotropis sp</i>	0,61	Agregada	<i>Protium sp</i>	-0,04	Aleatória
<i>Dipteryx odorata</i>	0,20	Aleatória	<i>Pseudolmedia laevigata</i>	0,56	Agregada
<i>Dussia tessmannii</i>	-0,11	Aleatória	<i>Pseudolmedia laevis</i>	0,55	Agregada
<i>Elaeoluma nuda</i>	1,00	Agregada	<i>Qualea paraensis</i>	0,52	Agregada
<i>Emmotum nitens</i>	0,54	Agregada	<i>Rinoreocarpus ulei</i>	0,57	Agregada
<i>Endlicheria ruforamula</i>	0,51	Agregada	<i>Sacoglottis guianensis</i>	0,52	Agregada
<i>Endlicheria sp</i>	0,27	Aleatória	<i>Sacoglottis mattogrossensis</i>	-0,02	Aleatória
<i>Enterolobium schomburgkii</i>	-0,09	Aleatória	<i>Schefflera morototoni</i>	0,52	Agregada
<i>Eriotheca globosa</i>	-0,07	Aleatória	<i>Simarouba amara</i>	-0,04	Aleatória
<i>Erisma bicolor</i>	0,52	Agregada	<i>Siparuna guianensis</i>	0,61	Agregada
<i>Erisma uncinatum</i>	0,53	Agregada	<i>Sloanea guianensis</i>	0,51	Agregada
<i>Erythroxyllum mucronatum</i>	0,61	Agregada	<i>Sloanea nitida</i>	0,27	Aleatória
<i>Eschweilera carinata</i>	0,57	Agregada	<i>Sloanea rufa</i>	0,62	Agregada
<i>Esenbeckia febrifuga</i>	0,58	Agregada	<i>Sorocea guilleminiana</i>	-0,11	Aleatória
<i>Fareamea capillipes</i>	0,59	Agregada	<i>Sterigmataleum obovatum</i>	1,00	Agregada
<i>Goupia glabra</i>	0,52	Agregada	<i>Strychnos subcordata</i>	0,50	Agregada
<i>Guatteria anthracina</i>	1,00	Agregada	<i>Stryphnodendron racemiferum</i>	0,53	Agregada
<i>Guatteria olivacea</i>	0,62	Agregada	<i>Swartzia arborescens</i>	0,67	Agregada
<i>Guatteria schomburgkiana</i>	0,50	Agregada	<i>Sweetia fruticosa</i>	0,61	Agregada
<i>Heistera sp</i>	-0,02	Aleatória	<i>Tachigali glauca</i>	0,58	Agregada
<i>Heisteria densifrons</i>	0,51	Agregada	<i>Tachigali myrmecophila</i>	-0,02	Aleatória
<i>Helicostylis scabra</i>	0,59	Agregada	<i>Tachigali paniculata</i>	0,50	Agregada
<i>Helicostylis sp</i>	-0,09	Aleatória	<i>Tachigali setifera</i>	0,59	Agregada
<i>Himatanthus sucuuba</i>	-0,11	Aleatória	<i>Tachigali venusta</i>	0,55	Agregada
<i>Hirtella racemosa</i>	0,54	Agregada	<i>Tachigali vulgaris</i>	0,68	Agregada
<i>Hirtella sp</i>	0,61	Agregada	<i>Tapirira guianensis</i>	0,26	Aleatória
<i>Hymenolobium modestum</i>	0,57	Agregada	<i>Tapura amazonica</i>	-0,02	Aleatória
<i>Hymenolobium petraeum</i>	-0,04	Aleatória	<i>Terminalia amazonia</i>	0,51	Agregada
<i>Inga alba</i>	0,55	Agregada	<i>Tetragastris altissima</i>	0,52	Agregada
<i>Inga cordatoalata</i>	0,55	Agregada	<i>Tetragastris panamensis</i>	-0,04	Aleatória
<i>Inga obidensis</i>	0,51	Agregada	<i>Toulicia sp</i>	-0,02	Aleatória
<i>Inga sp</i>	0,51	Agregada	<i>Tovomita sp</i>	0,61	Agregada
<i>Inga thibaudiana</i>	-0,02	Aleatória	<i>Trattinnickia burserifolia</i>	0,51	Agregada

(Continua)

Tabela A.2 - Conclusão

<b>Espécie</b>	<b>IMN</b>	<b>Distribuição</b>	<b>Espécie</b>	<b>IMN</b>	<b>Distribuição</b>
<i>Iryanthera laevis</i>	1,00	Agregada	<i>Trattinnickia rhoifolia</i>	0,53	Agregada
<i>Iryanthera ulei</i>	1,00	Agregada	<i>Trichilia cipo</i>	0,61	Agregada
<i>Jacaranda copaia</i>	0,53	Agregada	<i>Virola melinoni</i>	0,54	Agregada
<i>Laetia procera</i>	0,54	Agregada	<i>Vochysia ferruginea</i>	-0,02	Aleatória
<i>Licania canescens</i>	-0,02	Aleatória	<i>Vochysia guianensis</i>	0,51	Agregada
<i>Licania heteromorpha</i>	-0,02	Aleatória	<i>Vochysia maxima</i>	0,42	Aleatória
<i>Licania micrantha</i>	0,55	Agregada	<i>Xylopia amazonica</i>	-0,04	Aleatória
<i>Licania octandra</i>	0,51	Agregada	<i>Xylopia nitida</i>	-0,04	Aleatória
<i>Licania sp</i>	-0,02	Aleatória	<i>Xylopia parviflora</i>	0,54	Agregada
<i>Mabea angularis</i>	1,00	Agregada	<i>Xylopia sp</i>	0,51	Agregada
<i>Mabea fistulifera</i>	0,54	Agregada	<i>Zanthoxylum djalma batistae</i>	-0,02	Aleatória
<i>Manilkara huberi</i>	0,51	Agregada	<i>Zanthoxylum rhoifolium</i>	-0,04	Aleatória
<i>Maquira coriacea</i>	0,54	Agregada			

\*IMN: Índice de Morisita normalizado, variando de -1 a 1.